



UNIVERSIDADE ESTADUAL DE CAMPINAS
Faculdade de Engenharia Mecânica

JHON JAIRO PEREZ GELVES

**Lógica *Fuzzy* e Redes Neurais aplicadas para
previsão de curvas de carga de chuveiros elétricos
em programas de Eficiência Energética no Brasil**

CAMPINAS

2017

JHON JAIRO PEREZ GELVES

Lógica *Fuzzy* e Redes Neurais aplicadas para previsão de curvas de carga de chuveiros elétricos em programas de Eficiência Energética no Brasil

Tese de Doutorado apresentada à Faculdade de Engenharia Mecânica da Universidade Estadual de Campinas como parte dos requisitos exigidos para obtenção do título de Doutor em Planejamento de Sistemas Energéticos.

Orientador: Prof. Dr. Gilberto de Martino Jannuzzi
Coorientador: Prof. Dr. Conrado Augustus de Melo

ESTE EXEMPLAR CORRESPONDE À VERSÃO FINAL
DA TESE DEFENDIDA PELO ALUNO JHON JAIRO
PÉREZ GELVES E ORIENTADA PELO
PROF. DR. GILBERTO DE MARTINO
JANNUZZI.....

.....
ASSINATURA DO ORIENTADOR

**CAMPINAS
2017**

Agência(s) de fomento e nº(s) de processo(s): Não se aplica.

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Luciana Pietrosanto Milla - CRB 8/8129

P415L Perez Gelves, Jhon Jairo, 1978-
Lógica *Fuzzy* e redes neurais aplicadas para previsão de curvas de carga de chuveiros elétricos em programas de eficiência energética no Brasil / Jhon Jairo Perez Gelves. – Campinas, SP : [s.n.], 2017.

Orientador: Gilberto de Martino Jannuzzi.

Coorientador: Conrado Augustus de Melo.

Tese (doutorado) – Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica.

1. Previsão de carga. 2. Aquecedores elétricos de água. 3. Eficiência energética. 4. Inteligência artificial. I. Jannuzzi, Gilberto de Martino, 1955-. II. Melo, Conrado Augustus de. III. Universidade Estadual de Campinas. Faculdade de Engenharia Mecânica. IV. Título.

Informações para Biblioteca Digital

Título em outro idioma: *Fuzzy logic and applied neural networks for prediction of charge curves of electric showers in energy efficiency programs in Brazil*

Palavras-chave em inglês:

Load forecasting

Electric showers

Energy efficiency

Artificial intelligence

Área de concentração: Planejamento de Sistemas Energéticos

Titulação: Doutor em Planejamento de Sistemas Energéticos

Banca examinadora:

Gilberto de Martino Jannuzzi [Orientador]

Carla Kazue Nakao Cavaliero

Luiz Carlos Pereira da Silva

Paulo Henrique de Mello Sant Ana

Jose Antônio Perrella Balestieri

Data de defesa: 17-02-2017

Programa de Pós-Graduação: Planejamento de Sistemas Energéticos

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA MECÂNICA
COMISSÃO DE PÓS-GRADUAÇÃO EM
PLANEJAMENTO DE SISTEMAS ENERGÉTICOS
DOUTORADO EM PLANEJAMENTO DE SISTEMAS
ENERGÉTICOS

TESE DE DOUTORADO

**Lógica *Fuzzy* e Redes Neurais aplicadas para
previsão de curvas de carga de chuveiros elétricos
em programas de Eficiência Energética no Brasil**

Autor: **Jhon Jairo Perez Gelves**

Orientador: Prof. Dr. Gilberto De Martino Jannuzzi

Coorientador: Prof. Dr. Conrado Augustus de Melo

A Banca Examinadora composta pelos membros abaixo aprovou esta Tese:

**Prof. Dr. Gilberto De Martino Jannuzzi, Presidente
FEM/UNICAMP**

**Profa. Dra. Carla Kazue Nakao Cavaliero
FEM/UNICAMP**

**Prof. Dr. Luiz Carlos Pereira da Silva
FEEC/UNICAMP**

**Prof. Dr. Paulo Henrique de Mello Sant Ana
CESC/UFABC**

**Prof. Dr. José Antônio Perrella Balestieri
DE/UNESP**

A Ata da defesa com as respectivas assinaturas dos membros encontra-se no processo de vida acadêmica do aluno.

Campinas, 17 de Fevereiro de 2017.

Dedicatória

*A la memoria de mis padres y de mi hermano Idinael que siempre
me cuidan desde el cielo, al presente y futuro de mi amada hija María Alejandra*

Agradecimentos

Em primeiro lugar, agradeço à Deus por ter iluminado meu caminho para alcançar esta grande meta.

Gostaria de agradecer aos meus orientadores, Prof. Dr. Gilberto De Martino Jannuzzi e Prof. Dr. Conrado Augustus de Melo, por me proporcionarem uma nova visão sobre o que é a pesquisa.

Ao meu irmão, Alvaro Pérez, pelas dicas e força durante o Doutorado; ao meu primo, Federico Nuñez, pelo grande apoio incondicional em minha vida e durante meu Doutorado; ao meu grande amigo, Pedro Drumond, pela grande amizade e apoio, no Brasil.

Ao grupo da sala, incluindo Rodolfo, Luciano, Carla, Amanda e Humberto.

Aos meus grandes amigos em Barão Geraldo – Andrés, Jhon Alexander, Juan Esteban, Juan Sebastian, Harold, Mariana, Edgar, Andrea, Edwin, André e Vicente.

Ao grupo Melcosul, Viviana, Carolina, Lorena, Laura, Giuseppe, André, Pedro C e Jorge.

Aos professores do Programa de Planejamento Energético da UNICAMP, especialmente, Arnaldo, Carla, Sergio, Paulo, Waldyr e Marcelo, pela formação recebida no Doutorado.

À família Drumond – Senhora Vera, Senhor Drumond e Fernanda e à família Nardi – Senhora Ernestina, Luiz e Francisco – grandes amigos durante minha estadia no Brasil.

À minha família e amigos na Colômbia e no Brasil pela força e apoio. É impossível enumerar todos, mas eles sabem que sou muito grato.

À fundação COLCIENCIAS e à Universidade de La Salle pelo financiamento do Doutorado.

Resumo

O consumo de energia elétrica do setor residencial corresponde à, aproximadamente, 25% da demanda energética total do Brasil. Um dos principais usos da energia nesse setor é o aquecimento de água para banho, sendo os chuveiros elétricos (CEs) os principais aparelhos usados para essa finalidade. De fato, o consumo dos CEs representa em média 21% do consumo do setor residencial. Nas regiões mais frias do país, Sul e Sudeste, com aproximadamente 110 milhões de habitantes, o consumo energético devido ao uso dos CEs é maior, atingindo 25 e 26%, respectivamente. Os CEs são principalmente usados das 18h às 21h e, por serem aparelhos que consomem bastante energia elétrica, com potência entre 4 e 8 kW, causam o maior incremento na demanda máxima no sistema elétrico brasileiro. Nas comunidades de baixa renda, o consumo de eletricidade devido aos CEs é crítico, já que a mesma pode representar em torno de 23% da conta de energia elétrica. Neste trabalho, foi feita a concepção e a implementação de um Sistema de Inferência *Fuzzy* (SIF) e de uma Rede Neural Artificial (RNA) para determinar a demanda de curva diária dos CEs. Foi avaliado o impacto dos Programas de Eficiência Energética (PEEs) da Agência Nacional de Energia Elétrica (ANEEL) em comunidades de baixa renda, localizadas no Estado do Rio de Janeiro, nas cidades de Rio de Janeiro e Volta Redonda. O estudo foi desenvolvido a partir de medições em 75 residências. Adicionalmente, dois tipos de CEs foram comparados o controlador eletrônico de temperatura (CECET) e o recuperador de calor (CERC). Os resultados obtidos pelos métodos SIF e RNA foram validados usando o erro absoluto médio (EAM) e o erro percentual absoluto médio (EMPA). Essa validação mostrou que, na maioria dos casos, os resultados das simulações reproduziram adequadamente a demanda de curva diária dos CEs. O uso de técnicas não tradicionais, tais como *Fuzzy* e RNAs, pode contribuir significativamente à pesquisa e a avaliação dos PEEs da ANEEL, no Brasil. Esse tipo de ferramenta pode ser usado em comunidades de tamanho pequeno, com condições socioeconômicas similares, permitindo prever o impacto dos PEEs na economia de energia e na redução da potência máxima.

Palavras-Chave: Previsão de carga, aquecedores elétricos de água, eficiência energética, inteligência artificial.

Abstract

The electricity consumption in the residential sector in Brazil, corresponds to approximately 25% of the total electricity demand. The electric showers (ES) represent, on average, about 21% of the total residential electricity consumption. In colder regions, such as the Southeast and South, the electricity demand of ESs is even higher, about 26% and 25%, respectively. About 110 million people live in these regions, where the use of ES is widespread. The power consumption of ESs varies between 4-8 kW. In the residential sector, the ESs are used mainly from 18:00 to 21:00 hours, which is accountable for the maximum peak demand in the Brazilian electrical system. The use of ESs in terms of electricity costs is very significant, mainly in low-income households, where the electricity consumption of ESs represents about 23% of the monthly electricity bill. This thesis addresses the design and implementation of a Fuzzy Inference System (FIS) and an Artificial Neural Network (ANN) to determine daily demand curves of residential ESs. The present study evaluated the impacts of Energy Efficiency Programs (EEPs) in low-income communities located in two cities in the state of Rio de Janeiro – Rio de Janeiro and Volta Redonda. Additionally, two different ES devices are compared: the electric shower with temperature control (ESTC) and the electric shower with heat recovery (ESHR). The study was based on measurements made in 75 households in different low-income neighborhoods. Forecasting results were validated using Mean Absolute Error (MAE) and Mean Absolute Percentage Error (MAPE). This validation showed that, in most cases, the results were accurate. The use of non-traditional techniques, such as FIS and ANN, can contribute significantly to the investigation and assessment of EEPs in developing countries. These tools can be used in small and medium-sized communities with similar socio-economic conditions, which allow for the determination, in advance, of the impact of EEPs in energy saving and reduction of peak demand in the communities. We conclude that accurate models to forecast electricity consumption are indispensable for electric utilities in the process of design, planning and operating power systems. Furthermore, these forecasting approaches allow decision-makers to implement EEP-related targets.

Keywords: Load forecasting, electric showers, energy efficiency, artificial intelligence.

Lista de Ilustrações

Figura 2.1- Investimentos nos Programas de Eficiência Energética (PEEs), nas comunidades de baixa renda nos EUA.	26
Figura 2.2 - Consumo de energia elétrica (kWh) por residência, em países na América Latina.	34
Figura 2.3 - Porcentagens dos PEEAs desde o começo do ProPEE até dezembro de 2015.	41
Figura 2.4 - Visão geral da abordagem <i>Bottom-Up</i>	45
Figura 3.1- Fluxograma metodológico para a previsão das curvas de demanda nos CE, usando a lógica <i>Fuzzy</i> e as RNAs.	51
Figura 3.2 - Chuveiro elétrico com controlador eletrônico de temperatura nos PEEs da ANEEL.	64
Figura 3.3 - Princípio de funcionamento do recuperador de calor nos PEEs da ANEEL.	65
Figura 3.4 - Modelo usado para a previsão do consumo de energia elétrica.	66
Figura 3.5 - Sistema de inferência <i>Fuzzy</i> para a previsão da curva de demanda.	72
Figura 3.6 - Fluxograma para a previsão das curvas de carga usando a abordagem <i>Fuzzy</i>	73
Figura 3.7 - Rede neural de um neurônio com n entradas.	76
Figura 3.8. Diagrama de fluxo para a previsão das curvas de carga usando a abordagem da RNA.	79
Figura 4.1 - Cidades de aplicação da metodologia no Estado do Rio de Janeiro.	84
Figura 4.2 - Medidor <i>data logger</i> usado nas medições das amostras.	86
Figura 4.3 - Dados das medições considerando aproximação em tempo de banho e quantidade de banhos.	88
Figura 4.4 - Aproximação considerando união de tempo de banho e quantidade de banhos.	89
Figura 4.5 - Distribuição gaussiana para a faixa entre 500 W e 1000 W.	90
Figura 4.6 -Funções de pertinência da quantidade de banhos.	91
Figura 4.7 - Funções de pertinência do tempo de banho.	92
Figura 4.8 - Função de pertinência da carga estimada.	93
Figura 4.9 - Processo de <i>defuzzificação</i> (entradas e saída do modelo).	96
Figura 4.10 - Arquitetura da rede neural usada (FFNN) para a previsão das curvas de carga.	100

Figura 4.11 - Previsão da curva de carga antes e depois da inserção do CECET na amostragem 1 (aproximação).	103
Figura 4.12 - Previsão da curva de carga antes e depois da inserção do CECET na amostragem 1 (união).	104
Figura 4.13 - Erro na amostra 1 caso CECET (aproximação): (a) EAM; (b) EMPA.	105
Figura 4.14 - Erro na amostragem 1, caso CECET (união). (a) EAM; (b) EMPA.	107
Figura 4.15 - Previsão da curva de carga antes e depois da inserção do CERC na amostragem 2 (aproximação).	109
Figura 4.16 - Previsão da curva de carga antes e depois da inserção do CERC recuperador de calor na amostragem 2 (união).	110
Figura 4.17 - Erro na amostragem 2, caso CERC (aproximação). (a) EAM; (b) EMPA.	111
Figura 4.18 - Erro na amostragem 2, caso CERC (união). (a) EAM; (b) EMPA.	113
Figura 4.19 - Previsão da curva de carga antes e depois da inserção do recuperador de calor na amostragem 3, caso CERC.	115
Figura 4.20 - Erro na amostragem 3, caso CERC. (a) EAM; (b) EMPA.	116
Figura 4.21 - Comparação entre CE (<i>ex-ante</i>), CECET (<i>ex-post</i>) e CERC (<i>ex-post</i>).	118
Figura 4.22 - Economia de energia elétrica na amostragem 1. a) CE antes da troca e b) CECET.	120
Figura 4.23- Histogramas da potência e quantidade de banhos na amostragem 1: a) CE e b) CECET.	124
Figura 4.24- Histogramas do tempo e quantidade de banhos na amostragem 1: a) CE e b) CECET.	125
Figura 4.25 - Economia de energia elétrica na amostragem 2. a) CE antes da troca e b) CERC.	127
Figura 4.26- Histogramas da potência e quantidade de banhos na amostragem 2: a) CE e b) CERC.	130
Figura 4.27- Histogramas do tempo e quantidade de banhos na amostragem 2: a) CE e b) CERC.	131
Figura 4.28 - Economia de energia elétrica na amostragem 3. a) CE antes da troca e b) CERC.	133
Figura 4.29. Histogramas da potência e quantidade de banhos na amostragem 3: a) CE e b) CERC.	136
Figura 4.30. Histogramas do tempo e quantidade de banhos na amostragem 2: a) CE e b) CERC.	137

Lista de Tabelas

Tabela 1.1 - Comparações das porcentagens do consumo de energia elétrica dos aparelhos elétricos residenciais, por região no Brasil	18
Tabela 2.1 - Alguns estudos baseados na abordagem <i>Bottom-Up</i>	47
Tabela 3.1 - Tamanho da amostra de acordo com a ProPEE-ANEEL 2008, nos PEEs da ANEEL de baixa renda no Brasil.	53
Tabela 4.1 - Descrição de cada amostra dos PEEs da ANEEL para CE em Volta Redonda e no Rio de Janeiro.	85
Tabela 4.2 - Funções de pertinência para a quantidade de banhos (aproximação).	92
Tabela 4.3 - Funções de pertinência para o tempo de banho (aproximação).	93
Tabela 4.4 - Funções de pertinência para a saída de previsão de carga (aproximação).	94
Tabela 4.5 - Regras do SIF.	95
Tabela 4.6 - Funções de pertinência para a quantidade de banhos e o tempo de banho (união).	97
Tabela 4.7 - Função de pertinência para a saída de previsão de carga (união).	98
Tabela 4.8 - Parâmetros da RNA.	101
Tabela 4.9 - Erro EAM e EMPA para a previsão do primeiro pico e máxima demanda na amostragem 1, caso CECET.	108
Tabela 4.10 - EAM e EMPA para a previsão do primeiro pico e máxima demanda na amostragem 2, caso CERC.	114
Tabela 4.11. Erro EAM e EMPA para a previsão do primeiro pico e máxima demanda na amostragem 3, caso CERC.	117
Tabela 4.12. Distribuição dos banhos na amostra 1 em potência com CE e o CECET.	122
Tabela 4.13 - Distribuição dos banhos na amostra 1 no tempo com CE e o CECET.	123
Tabela 4.14. Distribuição dos banhos na amostra 2 em potência com CE e o CERC.	128
Tabela 4.15 - Distribuição dos banhos na amostra 2 no tempo com CE e o CERC.	129
Tabela 4.16- Distribuição dos banhos na amostra 3 em potência com CE e o CERC.	134
Tabela 4.17. Distribuição dos banhos na amostra 3 no tempo com CE e o CERC.	135
Tabela 4.18. Resumo dos efeitos dos PEEs na economia de energia e no tempo.	138

Lista de Abreviaturas e Siglas

ACEEE	– <i>American Council for an Energy-efficient Economy</i>
AG	– Algoritmos Genéticos
ANEEL	– Agência Nacional de Energia Elétrica
ANP	– Agência Nacional do Petróleo, Gás Natural e Biocombustíveis
BPC	– Benefício de Prestação Continuada
BPCAS	– Benefício de Prestação Continuada da Assistência Social
BRE	– <i>Building Research Establishment</i>
CE	– Chuveiro Elétrico
CERC	– Chuveiro elétrico com recuperador de calor
CECET	– Chuveiro elétrico com controlador eletrônico de temperatura
CREEM	– <i>Canadian Residential Energy End-Use Model</i>
LED	– Diodo emissor de luz
EAM	– Erro Absoluto Médio
EE	– Eficiência Energética
EMPA	– Erro Médio Porcentual Absoluto
EM&V	– <i>Evaluation, Measurement and Verification</i>
ENCE	– Etiqueta Nacional de Conservação e Energia
EPDB	– <i>Energy Performance of Building Directive</i>
EUA	– Estados Unidos da América
GLD	– Gerenciamento pelo Lado da Demanda
IEE	– Índice de Eficiência Energética
IEI-LA	– <i>International Initiative -Latin America</i>
LED	– <i>Light Emitting Diode</i>
LFC	– Lâmpada fluorescente compacta
LM	– Função de Otimização <i>Levenberg-Marquadt</i>
INMETRO	– Instituto Nacional de Metrologia, Qualidade e Tecnologia
IPEEC	– <i>International Partnership for Energy Efficiency Corporation</i>
IPCHMR	– <i>International Pacific Consulting and Harrison Market Research National Energy</i>

LIHEAP	– <i>Low Income Energy Assistance Program</i>
MEPS	– <i>Minimum Energy Performance Standards</i>
M&V	– Medição e Verificação
MLP	– <i>Multilayer Perceptron</i>
NEEA	– <i>National Energy Efficiency Action</i>
NIS	– Número de Identificação Social
PEE	– Programa de Eficiência Energética
PEEA	– Programa de Eficiência Energética pela ANEEL
PIB	– Produto Interno Bruto
PIMVP	– Protocolo Internacional para Medição e Verificação de Performance
PROCEL	– Programa Nacional de Conservação de Energia Elétrica
ProPEE	– Procedimentos do Programa de Eficiência Energética
P&D	– Pesquisa e Desenvolvimento
RMSE	– <i>Root-Mean-Square Error</i>
RNAs	– Redes Neurais Artificiais
SGPEE	– Sistema de Gestão do PEE
SIF	– Sistema de Inferência <i>Fuzzy</i>
SIN	– Sistema Interligado Nacional
UE	– União Europeia
UKCDM	– <i>UK Carbon Domestic Model</i>

.....

SUMÁRIO

Resumo	7
Abstract	8
Lista de Ilustrações	9
Lista de Tabelas	11
1 INTRODUÇÃO	16
1.1 Motivação	20
1.2 Objetivos	21
1.3 Estrutura da Tese	21
2 REVISÃO BIBLIOGRÁFICA	23
2.1 Programas de Eficiência Energética: Experiências Internacionais	23
2.1.1 Estados Unidos da América	24
2.1.2 Europa	27
2.1.3 China	31
2.1.4 Austrália	32
2.2 Programas de Eficiência Energética: América Latina	33
2.3 Programas de Eficiência Energética: Experiência Brasileira	39
2.4 Métodos de projeção da demanda	44
2.4.1 Métodos de previsão de carga de curto prazo	48
3 METODOLOGIA PARA A PREVISÃO DE CURVAS DE CARGA NOS CHUVEIROS ELÉTRICOS, USANDO AS ABORDAGENS SIF E RNA	50
3.1 Obtenção dos dados (PEEs da ANEEL) – Etapa 1	52
3.1.1 Desenho de um PEE	52
3.1.2 Obtenção dos dados a partir de comunicação com a concessionária	55
3.1.3 Pesquisas de opinião	56
3.2 Chuveiros elétricos usados nos PEEAs nas amostras – Etapa 2	63
3.3 Modelagem usando inteligência artificial	66
3.3.1 Modelagem <i>Fuzzy</i> – Etapa 3	66
3.3.2 Modelagem usando Redes Neurais – Etapa 3	74
3.3.3 Vantagens e desvantagens das abordagens <i>Fuzzy</i> e RNA	80
3.4 Validade e verificação dos resultados – Etapa 5	81

4 APLICAÇÃO DA METODOLOGIA PARA A PREVISÃO DE CURVAS DE CARGA NOS CHUVEIROS ELÉTRICOS, USANDO SIF E RNA.....	83
4.1 Amostras e tratamento de dados – etapas 1 e 2	83
4.1.1 Amostras	83
4.1.2 Tamanho da amostra	84
4.1.3 Tratamento dos dados	85
4.2 Aplicações das abordagens <i>Fuzzy</i> e a RNA – Etapas 3 e 4	89
4.2.1 Modelagem do SIF	90
4.2.2 Modelagem usando a RNA.....	99
4.3 Resultados e aplicações das abordagens <i>Fuzzy</i> e RNA às amostras – Etapa 5.....	102
4.3.1 O caso do chuveiro elétrico com controlador de temperatura (CECET)	102
4.3.2 O caso do chuveiro elétrico com recuperador de calor (CERC)	109
4.3.3 Normalização das curvas para o CECET e o CERC	117
4.3.4 Resultados dos PEEs da ANEEL nas amostras	119
4.4 Resumo dos resultados dos PEEs (união).....	138
5 CONCLUSÕES E SUGESTÕES PARA PRÓXIMOS TRABALHOS	139
5.1 Conclusões	139
5.2 Limitações deste trabalho	141
5.3 Sugestões para próximos trabalhos.....	142
Referências	143
Anexo A.....	157
Anexo B	158

1 INTRODUÇÃO

No Brasil, existem aproximadamente 66 milhões de residências, que foram responsáveis por consumir 132.000 GWh, em 2014. Esse consumo representou quase 25% do consumo final de eletricidade do período (BEN, 2015). Lançando um olhar sobre o consumo total de eletricidade, apenas do setor residencial por região, 6% do consumo total diz respeito à região Norte, 7,8% à região Centro-Oeste, 19% à região Nordeste, 16% à região Sul e 51,1% à região Sudeste, no ano 2015 (SAD-ANEEL, 2015). O consumo das regiões Sul e Sudeste juntos, representam 67% do total consumido pelo setor residencial. Isso é consequência do número de habitantes, aproximadamente 110 milhões de habitantes, e do maior grau de desenvolvimento destas regiões, segundo o Instituto Brasileiro de Geografia e Estatística – IBGE (IBGE, 2009).

Existem muitos estudos que estimam o consumo de energia elétrica de equipamentos de uso residencial, no Brasil (JANNUZZI; SCHIPPER, 1991; ALMEIDA; SCHAEFFER; LA ROVERE, 2001; FEDRIGO; GOSCH; LAMBERTS, 2007). Não obstante, destacam-se três trabalhos nessas estimativas, os quais fizeram um detalhamento, por região e por aparelho elétrico residencial, das porcentagens do consumo de energia elétrica, que serão apresentados na Tabela 1.1.

A pesquisa desenvolvida por Almeida *et al.* (2001), realizou uma estimativa relacionada ao possível potencial de conservação de energia elétrica, entre os anos 2000 e 2020. Esse trabalho foi feito a partir de dados do PROCEL de 1997, verificando-se que os aparelhos de maior consumo de energia elétrica no Brasil são o chuveiro elétrico (CE), com 20,7%, o ar-condicionado, com 29,9%, e a geladeira, com 34,1%, aparelhos nos quais se observa maior potencial de conservação de energia elétrica.

O Programa Nacional de Conservação de Energia Elétrica – PROCEL, desenvolveu uma pesquisa no ano de 2007 (PROCEL, 2007), com dados do ano sobre a demanda de energia elétrica nos aparelhos residenciais no Brasil. Segundo este estudo, o CE apresentou demanda de 24,0%, o ar-condicionado, demanda de 20,0%, e a geladeira, demanda de 22,0%. Finalmente, um último trabalho em relação aos usos finais da energia elétrica em aparelhos elétricos residenciais (FREDRIGO *et al.* 2009), foi feito de acordo com as medições da pesquisa feita pela PROCEL, em 2005. Neste trabalho, os cálculos foram feitos por região, em particular na região Sudeste, tem-se consumo de 22% para CE, 1% para ar-condicionado e

32% para geladeira. Esse trabalho baseou-se em medições realizadas em 284 cidades brasileiras, que incluíram um total de 5625 domicílios (PROCEL, 2007).

A Tabela 1.1 mostra de forma detalhada por aparelho e região, as porcentagens comparativas do consumo de energia elétrica nos três estudos mencionados anteriormente, em relação aos aparelhos elétricos residenciais CE, ar-condicionado e geladeira.

Em resumo os equipamentos elétricos residenciais de maior consumo nas regiões Sudeste e Sul são CE, geladeira e ar-condicionado. Com exceção do ar-condicionado, os outros aparelhos supracitados existem na maioria das residências no Brasil, nas comunidades de baixa renda. De acordo com a Tabela 1.1, os CEs representam um consumo de 2% na região Norte, 9% no Nordeste, 28% no Centro-Oeste, 26% no Sudeste e 25% no Sul (PROCEL, 2007).

Nas regiões Sul, Sudeste e Centro-Oeste, o aquecimento de água é feito, principalmente, por energia elétrica, sendo este método responsável por 95,5%, 92,9% e 86,1% do aquecimento, respectivamente. Nas regiões Nordeste e Norte, o uso de energia elétrica no aquecimento de água para banho é menor, sendo 74,9% e 86% respectivamente. No Brasil, como um todo, o aquecimento de água por energia elétrica representa 87%, por gás, representa 4,2% e por energia solar, 0,6% (IBGE, 2009). Isso mostra a pouca diversificação existente para o aquecimento de água no setor residencial no Brasil, sendo principalmente dependente da energia elétrica (CASTRO, 2014).

No que diz respeito aos CEs, as resistências elétricas usadas variam entre 4 e 8 kW (NASPOLINI; MILITÃO; RÜTHER, 2010) e são responsáveis pela maior parte do pico de demanda no Sistema Interligado Nacional (SIN), entre as 18h e 21h (PASSOS; CARDEMIL; COLLE, 2014). O chuveiro elétrico é responsável por 23% da carga no horário de pico (CASTRO, 2014). No que diz respeito às regiões Sul e Sudeste, o chuveiro chegou a responder por até 40% do consumo de energia elétrica no horário de pico, entre 18h e 19h (CASTRO, 2014).

Tabela 1.1 - Comparações das porcentagens do consumo de energia elétrica dos aparelhos elétricos residenciais, por região no Brasil (Ordem cronológica).

Aparelho	Região														
	Norte (%)			Nordeste (%)			Centro-Oeste (%)			Sudeste (%)			Sul (%)		
Chuveiro	4	2	1	7	9	7	23	28	11	23	26	22	22	25	41
Ar-condicionado	9	40	3	3	27	2	2	18	2	3	11	1	2	32	1
Geladeira e Freezer	35	29	50	41	34	47	33	29	43	33	27	32	32	23	21
Lâmpadas	20	14	20	18	11	18	12	12	12	11	19	11	11	8	11
Outros ¹	31	15	37	30	19	37	29	13	37	29	16	37	33	12	33
Autor	(a)	(b)	(c)	(a)	(b)	(c)	(a)	(b)	(c)	(a)	(b)	(c)	(a)	(b)	(c)

Fontes: (a) Estudo desenvolvido por Almeida *et al.* (2001), dados de 1997; (b) Estudo desenvolvido pela (PROCEL, 2007), dados de 2005 e (c) Estudo desenvolvido por Fedrigo *et al.* (2009) dados de 2007.

¹ Outros equipamentos: televisores, aparelhos de som, lava louças, secadoras, micro-ondas.

Esse aumento no pico de demanda, como consequência do uso do CE, também traz um efeito negativo para as concessionárias e, principalmente, para os consumidores, devido aos custos associados à operação adequada dos sistemas de distribuição (PASSOS; CARDEMIL; COLLE, 2014). Além disso, nas residências de baixa renda, o chuveiro elétrico tem uma participação representativa no total da conta de energia elétrica, em torno de 23% (NASPOLINI; MILITÃO; RÜTHER, 2010).

Ações que visem a evitar o desperdício de energia por parte do usuário final devem incluir a questão da Eficiência Energética (EE) de equipamentos elétricos de uso residencial. Nesse contexto, em 1999, foram criados os Programas de Eficiência Energética (PEEs) pela Agência Nacional de Energia Elétrica – ANEEL (ANEEL, 2015). Os PEEs da ANEEL (PEEA) foram implementados em cerca de 100 concessionárias, com um montante de 0,5% da receita das companhias em projetos de EE, nos anos de 1998 a 2016.

De acordo com o Ministério de Minas e Energia, os investimentos entre 1998 e 2014 foram de aproximadamente 1,85 bilhões (Euros)². Em 2008, a ANEEL apresentou a Resolução Normativa 300 (ANEEL, 2008), com o objetivo de estabelecer critérios para aplicação de recursos nos PEEs. As concessionárias e permissionárias deveriam aplicar, no mínimo 50% da obrigação legal de investimento, em programas de eficiência energética voltados a comunidades de baixo poder aquisitivo.

Avaliar e determinar a economia de energia e o impacto na redução do pico de demanda dos PEEs é uma tarefa complexa, devido à necessidade de um tratamento adequado dos dados que possa ajudar a quantificar os ganhos de economia. A Resolução Normativa 556 de 2013 (ANEEL, 2013) da ANEEL, criou um guia para as distribuidoras, que informa os procedimentos para a elaboração e execução dos PEEs da ANEEL, denominado Procedimentos do Programa de Eficiência Energética (ProPEE). Este guia contém a estrutura e a forma de apresentação dos projetos de EE, as normas para contabilização dos custos dos PEEAs, assim como os critérios de avaliação e de fiscalização, e os tipos de projetos que podem ser realizados. Finalmente, em 2014, foi publicado o Guia de Medição e Verificação (M&V) (M&V-ANEEL, 2014), baseado no Protocolo Internacional para Medição e Verificação de Performance (PIMVP) (PIMVP-COMMITTEE, 2001). O ProPEE, seguindo o protocolo de M&V, promove a organização e padronização da informação, além de constituir um banco de dados que permite avaliar o real impacto dos PEEs no consumo de energia elétrica.

² Agência GIZ. informações disponíveis no site <<https://www.giz.de/en/downloads/giz2015-en-energy-efficiency-measurement-brasilien.pdf>>

1.1 Motivação

Atualmente, novos métodos estão sendo usados na previsão da demanda de energia elétrica para a concepção, planejamento e operação do sistema elétrico atendido pelas concessionárias de energia elétrica (BADRI; AMELI; BIRJANDI, 2012; MANDAL *et al.* 2006; LIAO; TSAO, 2004; WARWICK, 1997). A aplicação de modelos de previsão permite aos tomadores de decisão contar com ferramentas para avaliar, com um grau de incerteza menor, a implementação de ações focadas na eficiência energética e na redução da demanda máxima na ponta.

A lógica *Fuzzy* vem sendo usada desde a década de 1990, em previsões de consumo de energia (DE SILVA, 1995; PANDIAN *et al.* 2006; AL-KANDARI; SOLIMAN; EL-HAWARY, 2004). Alguns trabalhos que usaram a lógica *Fuzzy* para a previsão de curvas de carga foram desenvolvidos por Bakirtzis *et al.*, (1995), Senjyu *et al.* (1998) e Pandian *et al.* (2006), estando entre os mais relevantes, com resultados satisfatórios.

Outra alternativa bastante usada nos modelos de previsão de curto prazo são as Redes Neurais Artificiais (RNAs) (PAPALEXOPOULOS; HAO; PENG, 1994; KHOTANZAD; AFKHAMI-ROHANI; MARATUKULAM, 1998). As RNAs são boas técnicas em modelagem (MAHMOUD *et al.* 2012; BARUNÍK; MALINSKA, 2016). Em termos gerais, esses dois métodos, a lógica *Fuzzy* e as RNAs, são boas ferramentas de previsão para modelos de curto prazo (CHOW; WU; MOMOH, 2005).

Desde meados da década de 1990, os trabalhos científicos vêm-se focando em determinar a curva de carga com base em variáveis não tradicionais, por exemplo, relacionando os hábitos dos consumidores com a curva de carga (WALKER; POKOSKI, 1985; MICHALIK *et al.* 1997; ZÚÑIGA; CASTILLA; AGUILAR, 2014). Mais recentemente, também há outros trabalhos nos quais não se usam as variáveis tradicionais. A título de exemplificação, os trabalhos de Mamlook *et al.* (2009) e Mamlook (2006) fizeram a previsão usando técnicas de Inteligência Artificial (IA), tais como *Fuzzy* e RNAs, a partir de variáveis climáticas.

A principal motivação desta tese é fazer a previsão de curvas de carga, usando a IA, em comunidades de baixa renda. Esses métodos podem ser usados nos PEEs da ANEEL, com o objetivo de reduzir custos logísticos nas medições, além de avaliar previamente o impacto dos PEEAs nessas comunidades.

1.2 Objetivos

O objetivo geral da tese é aplicar métodos baseados em Inteligência Artificial, lógica *Fuzzy* e Redes Neurais Artificiais, para estimar curvas de carga de chuveiros elétricos com duas tecnologias usadas nos PEEs da ANEEL.

Para atender ao objetivo proposto, foram definidos os seguintes objetivos específicos, a serem alcançados ao longo do trabalho.

1. Conceber e implementar um Sistema de Inferência *Fuzzy* (SIF) e de Redes Neurais Artificiais (RNAs) para a previsão de curvas de carga de curto prazo.
2. Verificar a adequação e confiabilidade desses modelos para os casos avaliados através dos erros EAM e EMPA.
3. Avaliar e estimar a economia de energia e o impacto no pico de demanda das duas tecnologias de aquecimento de água aplicadas nos PEEs da ANEEL, a partir das amostras obtidas.

1.3 Estrutura da Tese

Esta tese é composta de 5 capítulos.

No **capítulo 1 (Introdução)** é feita uma breve exposição sobre a importância do CE no consumo de energia elétrica no Brasil, com base em várias referências. A seguir, é apresentada a motivação do trabalho assim como são expostos os objetivos da tese.

O **capítulo 2 (Revisão bibliográfica)** revisa a literatura relacionada às diversas questões que envolvem a EE nos PEEs desenvolvidos em diversas localidades, tais como Estados Unidos, Europa, Ásia, Austrália e América Latina, além de incluir um detalhamento focado nos programas de EE desenvolvidos no Brasil. Adicionalmente, são detalhados os métodos para previsões de curvas de carga, incluindo a abordagem *Bottom-Up* e técnicas de computação flexível como a Lógica *Fuzzy* e as RNAs.

No **capítulo 3 (Metodologia para a previsão de curvas de carga nos chuveiros elétricos, usando as abordagens *Fuzzy* e RNAs)** é apresentado o desenvolvimento

metodológico das abordagens *Fuzzy* e RNAs, para a previsão de curvas de carga de CEs, conforme descrito a seguir. Para obtenção das curvas de carga, são necessárias 5 etapas metodológicas e procedimentais, incluindo (i) obtenção dos dados; (ii) tipos de tecnologias de CE usados nos PEEs da ANEEL; (iii) e (iv) métodos de previsão empregando as abordagens *Fuzzy* e RNAs; e (v) validação do Erro Absoluto Médio (EAM) e do Erro Médio Porcentual Absoluto (EMPA).

O capítulo 4 (**Aplicação da metodologia para a previsão de curvas de carga nos chuveiros elétricos, usando SIF e RNA**) apresenta-se a aplicação da estrutura metodológica para a concepção e implementação das previsões das curvas de carga nos chuveiros elétricos, usando o Sistema de Inferência *Fuzzy* (SIF) e as Redes Neurais Artificiais (RNAs), por etapas. Descrevem-se os resultados obtidos nas previsões das curvas de cargas para chuveiros elétricos, nas três amostragens do estudo.

No capítulo 5 (**Conclusões e sugestões para próximos trabalhos**) são apresentadas as conclusões e sugestões para trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

Neste capítulo, apresenta-se uma revisão bibliográfica em duas etapas: (i) revisão dos Programas de EE desenvolvidos em diferentes países (cultural e geograficamente distantes), incluindo EUA, Alemanha, França, Áustria, China, Austrália, Argentina, Chile, Uruguai e Brasil; e (ii) uma revisão dos métodos de planejamento energético da demanda, especialmente focado na previsão de curto prazo, baseada nas abordagens *Fuzzy* e RNAs.

O objetivo dessa revisão é apresentar alguns dos PEEs realizados em comunidades de baixa renda, em países desenvolvidos e em desenvolvimento, para identificar resultados e tipos de programas de EE executados no setor residencial desses países.

2.1 Programas de Eficiência Energética: Experiências Internacionais

O setor residencial tem uma participação significativa no consumo de energia. No mundo, segundo Nejat *et al.* (2015), esse consumo representa 27% do total da energia consumida. Nos países desenvolvidos, o consumo de energia tem uma participação significativa no consumo final de energia no setor residencial. Por exemplo, em 2011 nos EUA, esse consumo foi de 22%, na Alemanha, foi de 25% e no Reino Unido, foi de 28%. Não obstante, existem alguns países desenvolvidos com níveis baixos de consumo de energia no setor residencial, como Canadá, com consumo de 16%, Japão, com 15% e Coreia do Sul, com 12% (NEJAT *et al.* 2015). Em relação aos países em desenvolvimento; o consumo de energia do setor residencial aumentou, como consequência da expansão da população, o desenvolvimento das cidades e o crescimento econômico, sendo de 25% na Rússia, 30% no Irã, 36% na Índia e 23% na China (NEJAT *et al.* 2015).

2.1.1 Estados Unidos da América

Nos EUA, os domicílios residenciais e as edificações comerciais consumiram 41% da energia primária, 72% do consumo de energia elétrica e 36% do consumo de gás em 2008 (DORIS; COCHRAN; VORUM, 2009; EERE, 2008). As políticas em EE do setor residencial aplicadas nos EUA, estão focadas nos seguintes aspectos da EE: (a) código de edificações (CHING; WINKEL, 2016); (b) Padrão Mínimo de Desempenho Energético (MEPS; do inglês, *Minimum Energy Performance Standard*) (TURIEL, 1999); (c) etiquetagem de aparelhos elétricos e informação aos consumidores sobre o consumo de longo prazo dos aparelhos elétricos e de gás, nos domicílios (ACEEE, 2016); (d) PEEs em comunidades de baixa renda; e (e) avaliação, medição e verificação (EM&V; do inglês, *Evaluation, Measurement and Verification*); outros aspectos a destacar são os incentivos financeiros e não financeiros nos créditos fiscais, para edificações e domicílios com uso eficiente da energia, e Pesquisa e Desenvolvimento (P&D) em edificações com zero consumo de energia (DORIS; COCHRAN; VORUM, 2009).

a) Código de Edificações

O uso do Código de Edificações permitiu, nos EUA, economia de energia em iluminação, aquecimento, ventilação e ar-condicionado. Os resultados mostram que o impacto desse Código foi uma eficiência nos prédios, em termos gerais, entre 12% e 16% comparando-se os anos de 2006 e 2009. Esse programa permitiu uma redução de 5,75 GW no pico de demanda e uma redução de 11 TWh no consumo (GRANADE *et al.* 2009). A título de exemplificação, o estado da Califórnia manteve os mesmos níveis de consumo por pessoa, desde 1974 (DORIS; COCHRAN; VORUM, 2009). O Código de Edificações tornou-se um dos aspectos mais importantes na política de EE nos EUA, nos setores residencial e comercial, devido ao tamanho do país e variedade de climas, além das diferenças na legislação nos diferentes estados da união.

b) Padrão Mínimo de Desempenho Energético (MEPS)

O MEPS é uma especificação relacionada com o desempenho energético de aparelhos de uso final. Esse padrão limita a quantidade máxima consumida em um aparelho. No caso

dos EUA, a Califórnia foi pioneira na introdução do padrão MEPS. Adotado nesse estado, a partir de 1978, reduziu o crescimento do consumo de eletricidade no uso final (NADEL, 2003).

Nos EUA, até 2010, 15 estados haviam adotado o MEPS: *Arizona, Califórnia, Connecticut, Flórida, Maine, Maryland, Massachusetts, Nevada, Nova Hampshire, Nova Jersey, Nova Iorque, Oregon, Rhode Island, Vermont e Washington*. (NADEL, 2003) Segundo estimativas da *American Council for an Energy-Efficient Economy* (ACEEE), a economia de energia com a aplicação do MEPS, entre 1978 e 2006, permitiu uma economia de 250 GWh, nos EUA. Isso representou uma redução de 6,5% na eletricidade projetada e uma redução de 7,6% na demanda na ponta, principalmente em aparelhos relacionados com sistemas de ar-condicionado e refrigeração (DORIS; COCHRAN; VORUM, 2009).

c) Etiquetagem e educação

Uma das ações relacionadas com planos de EE é a etiquetagem com a informação do consumo energético dos aparelhos elétricos residenciais. Essa informação permitiu aos consumidores, melhor decisão na compra de aparelhos elétricos. Os programas de etiquetagem foram legislados pela política nacional de conservação de energia, a partir de 1980, sob duas formas:

- Comparativa: os consumidores informam sobre o consumo anual de energia entre produtos da mesma classe. Esse tipo de etiquetagem é conhecido como *Energy Guide* (ENERGY GUIDE, 2017).
- Endosso (aval), no qual a etiqueta identifica o produto dentro de uma classificação conforme sua EE. Esse programa é conhecido como *Energy Star* e foi iniciado em 1992 (ENERGY STAR, 2016).

d) PEEs em comunidades de baixa renda

Nos EUA, destaca-se o “Programa de Assistência em Energia para Domicílios de Baixa Renda” (tradução livre do inglês, *Low Income Home Energy Assistance Program – LIHEAP*), iniciado em 1981, com a missão de ajudar famílias de baixa renda, principalmente aquelas

cujo custo da energia representa uma proporção significativa da renda no domicílio (LIHEAP, 2016). Esse programa está focado principalmente na assistência dos custos associados a:

- Contas de energia nas residências e ações de EE para reduzir o consumo de energia
- Crise no fornecimento de energia
- Climatização e reparações nos imóveis, relacionadas ao uso da energia

Na Figura 2.1, mostram-se os investimentos feitos, ano a ano, nos programas de EE, nas comunidades de baixa renda, entre os anos 1981 e 2011, nos EUA. É importante destacar que existe uma variedade de programas de EE nos diferentes estados, no entanto, o mais relevante é o LIHEAP, que teve expansão entre 2009 e 2010, por autorização do congresso (LIHEAP, 2016).




Figura 2.1- Investimentos nos Programas de Eficiência Energética (PEEs), nas comunidades de baixa renda nos EUA.

Fonte: Low Income Energy Assistance Program (LIHEAP, 2016).

e) Avaliação, medição e Verificação (EM&V)

Os programas de EE desenvolvidos pelas diferentes concessionárias nos EUA e implementados nas comunidades de baixa renda, precisam ser avaliados para determinação do

impacto dos mesmos. Para tanto, é preciso medir, verificar e avaliar os resultados dos programas de EE, a partir de informações precisas, transparentes e concisas. O objetivo da EM&V é determinar qual a economia de energia em um programa de EE, além de estimar quantitativamente os efeitos de longo prazo das ações desses programas e, finalmente, comparar os resultados da economia de energia, com os resultados de outros programas de EE, em diferentes concessionárias ou estados (EM&V, 2017).

2.1.2 Europa

Na Europa, o setor residencial representa quase 25% do consumo final de energia e aproximadamente 30% da demanda de eletricidade (BORG; KELLY, 2011). Verificou-se até 2006, um aumento de aparelhos elétricos, especialmente notebooks, televisores e ar-condicionados, associado à redução do tamanho das residências (ALMEIDA *et al.* 2006). Na Europa mediterrânea, o aumento do consumo de eletricidade no setor residencial, entre os anos 2002 e 2008, foi de 3,7% em comparação com os países da Europa Ocidental, que apresentaram um aumento de 2,0% (MASON; ASHER, 2010).

a) Projeto ODYSSEE-MURE

A Europa é um continente com uma quantidade ampla de programas de EE, com destaque para o projeto *ODYSSEE-MURE*, do qual fazem parte 27 países da União Europeia (UE) (LAPILLONNE *et al.* 2012). Esse projeto é composto por duas bases de dados complementares, uma chamada *ODYSSEE* e a outra chamada *MURE*, para diferentes setores, incluindo transporte, residencial, industrial e serviços. A base de dados *ODYSSEE* contém dados de indicadores de EE e emissões de CO₂, relacionados com o consumo de energia, enquanto a base de dados *MURE* contém avaliações do impacto das ações implementadas em EE (*ODYSSEE-MURE*, 2016). Com esse projeto, a UE tem como objetivos (1) obter um monitoramento do consumo de energia e das tendências em EE e (2) contribuir com a avaliação das políticas e ações em EE, além da implementação das ações dos planos nacionais de EE, *National Energy Efficiency Action Plans* (NEEAP).

O monitoramento da EE no setor residencial dos países da UE-27, participantes do projeto *ODYSSEE-MURE*, gerou os resultados descritos abaixo (LAPILLONNE *et al.* 2012; INTELLIGENT ENERGY EUROPE, 2015).

1. Melhoria de 1,8% na média anual na EE nas residências, desde o ano 2000, principalmente devido à etiquetagem de aparelhos com selos de EE (A+ a A++).
2. Redução de 1,5% no consumo médio nas residências, no período de 2000 a 2008.
3. Melhoria, nos aquecedores residenciais, a uma taxa anual média de 2,3%, entre 2000 e 2008.
4. No ano 2000, os aparelhos elétricos pequenos representavam aproximadamente 42% do consumo de energia elétrica nas residências, sendo que essa porcentagem aumentou para 55%, em 2012. Ou seja, esse incremento na quantidade de aparelhos elétricos pequenos em cada residência, resultou num aumento do consumo de energia elétrica nas residências europeias UE-27.
5. Em relação aos aparelhos elétricos grandes (refrigeradores e lavadoras) produzidos em 2012, estes são 35% mais eficientes em comparação aos produzidos na década de 1990.
6. Aumento na economia de energia em iluminação devido ao surgimento e difusão de novas tecnologias, em particular, as Lâmpadas Fluorescentes Compactas (LFCs) e os Diodos Emissores de Luz (LEDs; do inglês, *Light Emitting Diodes*).

Outro objetivo do projeto *ODYSSEE-MURE* é identificar mudanças no consumo de aparelhos elétricos. Nesse aspecto, verificou-se uma redução importante no consumo de aparelhos elétricos grandes (refrigeradores, freezers, lavadoras e secadoras), posto que no ano 2000, os refrigeradores representaram 34% do consumo total de energia elétrica de uma residência na UE-27, enquanto que em 2012, esse consumo representou 28% do total (INTELLIGENT ENERGY EUROPE, 2015). No caso dos freezers, essa redução foi de 4 pontos percentuais, devido às políticas de etiquetagem (os mesmos representavam 18% do consumo total no ano 2000, passando para 14%, no ano 2012). Quanto aos aparelhos elétricos pequenos (celulares, computadores, micro-ondas e dispositivos eletrônicos em geral), houve aumento de 41% para 55% na participação do consumo total, do ano 2000 para o ano 2012 (INTELLIGENT ENERGY EUROPE, 2015).

O selo de EE, para geladeiras, é dividido em quatro classes: (i) selo A+++ com um Índice de Eficiência Energética (IEE) menor que 22; (ii) selo A++ com um IEE entre 22 e 33;

(iii) selo A+ com um IEE entre 33 e 44; e (iv) selo A com um IEE entre 44 e 55 (COMEONLABELS, 2016). Em relação aos resultados, destacam-se a redução no consumo de energia elétrica nos aparelhos grandes, aumentando sua eficiência em 35% devido ao uso do programa de etiquetagem em EE na UE-27.

No ano 2000, somente 22,5% das geladeiras tinham selo de EE tipo A. Em 2005, a porcentagem de aparelhos com selo tipo A aumentou para 59% e 10% tinham selo tipo A+. Já em 2008, do total das geladeiras, 64,4% tinham selo A, 25,3% selo A+ e 2% selo A++ (ODYSSEE-MURE, 2016). Finalmente, em 2012, as geladeiras com selo A representavam 20%, com selo A+, representavam 64%, com selo A++, representavam 13% e com selo A+++, representavam 2%. A título de exemplificação, uma geladeira com selo A+++ consome, em média, 60% menos e uma geladeira com selo A++ consome, em média, 45% menos, quando comparadas a uma geladeira com selo A.

Quanto à iluminação, representava 12% do consumo total de energia elétrica no setor residencial, no ano 2000 e passou a 10%, em 2012 (ODYSSEE-MURE, 2016). Isso ocorreu, principalmente, pela ampla difusão das LFCs no início da década de 2000, seguida pela entrada dos LEDs nas residências, no começo da década de 2010. Por esta razão, espera-se que o consumo em iluminação continue reduzindo.

b) Descrição de outros programas de EE

A União Europeia (UE), a partir de 2010, estabeleceu a etiquetagem de aparelhos elétricos, como geladeiras, freezers, lavadoras e lâmpadas, usando os diferentes selos de EE – A, A+, A++ e A+++ (PÉREZ-LOMBARD *et al.* 2009).

Na Europa, as edificações são responsáveis por 40% do consumo total de energia e 36% das emissões de CO₂ (BUILDINGS - EUROPEAN COMMISSION, 2016). Nesse sentido, foi desenvolvida a legislação de desempenho energético de edificações, conhecida por suas iniciais EPDB (do inglês, *Energy Performance of Building Directive*). Esse PEE tem duas fases, EPDB e EPDB2 (RAILIO, 2005). Abaixo, descrevem-se os aspectos principais do programa EPDB.

- Os países da UE estabeleceram sistemas padronizados para verificar a EE dos sistemas de aquecimento e de ar-condicionado nas edificações.
- Nos anúncios de venda ou aluguel de prédios, deve constar a certificação de desempenho energético.

- Os prédios novos, a partir de 31 de dezembro de 2020, deverão ser edificações de consumo zero.

Os países da UE estabeleceram os padrões mínimos de desempenho energético para novas edificações e renovação de edificações.

c) PEEs em comunidades de baixa renda na Europa

ACHIEVE (INTELLIGENT ENERGY EUROPE, 2014) é um dos principais programas de EE realizado em comunidades de baixa renda na Europa. Os objetivos deste programa são: (i) fomentar o uso adequado da energia nas residências; (ii) reabilitação de prédios antigos e (iii) soluções para que famílias com consumo muito reduzido de energia, atinjam um consumo mínimo considerado adequado pela UE (INTELLIGENT ENERGY EUROPE, 2014). O programa conta com a participação de desempregados, voluntários e estudantes, que são treinados para realizar visitas nas comunidades de baixa renda e fazer levantamento de informações. Esse programa encontra-se em desenvolvimento na França, na Alemanha, no Reino Unido, na Bulgária e na Eslovênia. Os principais resultados do programa são: (i) a participação conjunta de prefeituras, trabalhadores sociais, agências de energia, escolas e colégios, além da participação dos moradores, nos locais onde os programas foram desenvolvidos; (ii) treinamento sobre o consumo dos aparelhos nas residências e o uso apropriado dos mesmos, para reduzir o consumo; (iii) foram visitadas mais de 2000 residências, o que permitiu uma economia de 150 euros e uma redução estimada de 320 kg de CO₂ por ano, em cada domicílio.

d) Resultados dos programas de EE em alguns países da Europa

Na Alemanha, tem sido desenvolvido o programa de EE *Electricity saving-check* (HOLLANDER; ROSER, 2015) em comunidades de baixa renda, desde 2008. Nesse PEE foram trocadas as lâmpadas antigas por lâmpadas mais eficientes e fornecidos bônus para a compra de geladeiras com certificação A+++, tecnologia que permite uma economia de 200 kWh por ano. O programa foi desenvolvido em mais de 100 comunidades de baixa renda.

Abaixo estão descritos outros programas desenvolvidos na Europa (HOLLANDER; ROSER, 2015).

- Áustria: o programa “*Trennungsprämie 2009-2010*” (HOLLANDER; ROSER, 2015) baseia-se, principalmente, na troca de aparelhos como geladeiras, novos fogões, lavadoras e secadoras. O programa teve muito sucesso, entregando bônus entre 50 e 100 euros, nas comunidades de baixa renda para a aquisição de aparelhos com selo de eficiência A++.
- Dinamarca: PEE para a substituição de aparelhos elétricos de refrigeração, produzidos entre 1998 e 2008 (NOERGAARD *et al.* 2007).
- Itália: Programa desenvolvido a partir do ano 2007, oferecia redução na tributação para substituição de geladeiras,
- Espanha: PEE desenvolvido em comunidades de baixa renda, para a substituição de aparelhos elétricos em residências, entre os anos 2005 e 2012.
- Suíça: Programa de financiamento para a substituição de aparelhos elétricos de refrigeração, produzidos entre 1997 e 2015.
- Holanda: PEE implementado em domicílios de baixa renda. Desenvolvido inicialmente de 2000-2003 e, posteriormente, de 2011-2012 (HARMELINK; JOOSEN; BLOK, 2005).

2.1.3 China

A China tem 30 anos de rápido crescimento econômico, o setor residencial é responsável por cerca de 24% do consumo total de energia e a China é o país com maior grau de emissões no mundo – 9,5 bilhões de toneladas de CO₂, no ano 2014 (JIANG, 2016). Em relação ao consumo de eletricidade, o setor residencial representou 13,3% do consumo total em 2012, o que representou um consumo de 459 kWh per capita (JIANG, 2016). A China apresenta vários programas de EE, alguns dos mais reconhecidos são: (i) padronização do consumo mínimo (MEPS) e (ii) etiquetagem de aparelhos.

a) Padrão Mínimo de Desempenho Energético (MEPS)

O programa MEPS chinês incluiu 40 produtos, os quais estão padronizados para um consumo mínimo de energia, dividido em cinco categorias de consumo, sendo 1 – baixa eficiência e 5 – alta eficiência. A partir de 2009, o governo chinês lançou um programa de subsídios para a manufatura de aparelhos elétricos e a gás mais eficientes, o que permitiu uma economia de 28 TWh por ano (KHANNA *et al.* 2013).

b) Etiquetagem de aparelhos

O programa de etiquetagem chinês foi usado principalmente para geladeiras, freezers, ares-condicionados e lâmpadas. Nas províncias de *Jiangsu*, *Sichuan* e *Shandong* foram avaliados, principalmente, o impacto desses programas. Os resultados são diversos nas diferentes províncias em relação à economia de energia (KHANNA *et al.*, 2013).

2.1.4 Austrália

A Austrália é um país com um amplo uso de aparelhos elétricos, inclusive acima da Europa Ocidental e com níveis de consumo similares aos EUA. A Austrália tem uma população aproximada de 25 milhões e com climas variados, o que gera a necessidade de sistemas de aquecimento e de ventilação (HARRINGTON; WILKENFELD, 1997).

Os principais programas de EE, desenvolvidos na Austrália são: (i) programa de etiquetagem de aparelhos elétricos; (ii) testes e padronização de aparelhos; (iii) programa de etiquetagem de aparelhos de gás e (iv) MEPS.

A seguir são discutidos e apresentados alguns resultados dos PEEs desenvolvidos na Austrália:

a) Programa de etiquetagem

Durante o começo da década de 1980 foi introduzida, na Austrália, grande quantidade de aparelhos elétricos de uso massivo nas residências. Em 1986, foi obrigatória a inclusão da etiquetagem nos aparelhos elétricos. De acordo com um estudo desenvolvido pela companhia

de consultoria *International Pacific Consulting and Harrison Market Research National Energy* (IPCHMR) (HARRINGTON; WILKENFELD, 1997), 86% dos consumidores consideraram importante a revisão de etiquetagem dos aparelhos e 25% dos usuários consideraram essa etiquetagem um fator decisivo na hora da compra de aparelhos elétricos.

b) Padrão Mínimo de Desempenho Energético (MEPS)

Nos anos de 1992 e 1993, foi avaliada a introdução, no mercado, da padronização mínima de aparelhos elétricos, conhecida como MEPS. O resultado foi a introdução do MEPS para refrigeradores, freezers e sistemas de aquecimento (WILKENFELD, 1993). Posteriormente, em 1995, foram incluídas no programa MEPS, as máquinas de lavar louça, secadoras de roupa e sistemas de ar-condicionado. Para as máquinas de lavar louça, o Ministério de Energia recomendou o uso de água fria, para reduzir o consumo de energia elétrica no setor residencial.

2.2 Programas de Eficiência Energética: América Latina

Na América Latina, foi desenvolvido um estudo completo em relação à EE, conhecido como Base de Indicadores de Eficiência Energética (BIEE). Este foi desenvolvido a partir de 2011 (BIEE, 2015), em colaboração com a Agência de Cooperação Alemã, GIZ,³ e com o apoio da Agência Francesa para a Energia e o Ambiente, ADEME,⁴ no marco da *International Partnership for Energy Efficiency Corporation* (IPEEC). Com a participação de 19 países da América Latina (Argentina, Bolívia, Brasil, Chile, Colômbia, Costa Rica, Cuba, Equador, El Salvador, Guatemala, Honduras, México, Nicarágua, Panamá, Paraguai, Peru, República Dominicana, Uruguai e Venezuela), o programa tem como expectativa produzir um conjunto de indicadores relacionados à EE, que permitam medir a evolução dos programas nacionais de EE.

³ Agência de Cooperação Alemã, GIZ. Informações disponíveis no site <<https://www.giz.de/en/worldwide/12055.html>>

⁴ L'Agence de l'environnement et de la maîtrise de l'énergie. Informações disponíveis no site <<http://www.ademe.fr/>>

Na Figura 2.2, são apresentados dados de 13 países da América do Sul e América Central, disponíveis no site da BIEE⁵, que permitiram diferenciar faixas de consumo de energia elétrica no setor residencial desses países. As curvas apresentadas representam o consumo de energia elétrica por residência, no período de 2000 a 2012 (CARPIO; COVIELLO, 2013). Os países foram divididos em três grupos conforme o consumo de energia elétrica residencial: (i) aqueles com consumo de 500 a 1.000 kWh (Nicarágua, Bolívia e El Salvador); (ii) aqueles com consumo de 1.000 a 2.000 kWh (Equador, Brasil, México, Republica Dominicana e Panamá); e (iii) aqueles com consumo de 2.000 a 3.000 kWh (Chile, Paraguai, Argentina, Uruguai e Costa Rica). O resultado mostra diferenças no consumo de energia elétrica no setor residencial na América Latina, com diferenças significativas entre os países do primeiro e terceiro grupo.




Figura 2.2 - Consumo de energia elétrica (kWh) por residência, em países na América Latina.

Fonte: Baseada na Base de dados do programa BIEE Base de Indicadores de Eficiência Energética (BIEE) (CARPIO; COVIELLO, 2013).

Selecionaram-se quatro países: Argentina, Chile, Uruguai e Brasil, em razão do grande consumo de energia elétrica por residência, para apresentar uma breve revisão dos programas de EE, com destaque para o Brasil. Não obstante, as informações disponibilizadas ao público são escassas e desatualizadas.

⁵ Base de Indicadores de Eficiência Energética (BIEE). <http://www.cepal.org/dmi/biee/>

a) Argentina

O setor elétrico argentino é o terceiro mercado elétrico da América Latina, sendo a geração térmica e a geração hidroelétrica, responsáveis por 57% e 39% da capacidade instalada, respectivamente. O restante é obtido por meio de fontes renováveis alternativas. O consumo de energia elétrica no setor residencial, corresponde a 29% do total. Essa porcentagem mostra a importância do consumo de energia elétrica no setor residencial, na Argentina. No que diz respeito ao uso de aparelhos nas residências em 2011, o consumo em iluminação foi de 28% e em refrigeração residencial foi de 34% (BIEE, 2015). O uso de chuveiros elétricos é reduzido, sendo muito usado o gás natural para aquecimento de água e aquecimento dos domicílios. A seguir são apresentados os principais PEEs relacionados com EE no setor residencial.

Programas de EE

1. PRONUREE – Programa Nacional de uso Racional e Eficiente da Energia: esse programa foi estabelecido em 2007, com a finalidade de implementar a etiquetagem de eletrodomésticos eficientes. Especificamente em 2009, foi feita a regulação para geladeiras e freezers de uso doméstico. A economia de energia elétrica, em geladeiras e geladeiras com freezers, foi de 305 GWh em 2008, 480 GWh em 2009, 710 GWh em 2010 e, finalmente, 950 GWh em 2011. Por sua vez, a Lei N° 26.473 proibiu a comercialização de lâmpadas incandescentes a partir de 31 de dezembro de 2010. Os resultados dessa proibição foram a substituição de 5 milhões de lâmpadas em 2008 e 10 milhões por ano em 2009 e 2010. De acordo com as estimativas do Ministério de Planificação Federal Argentino, o programa PRONUREE permitiu a economia de 4.000 GWh no ano de 2011, o que é o equivalente ao consumo residencial de 3,4% desse ano (IGLESIAS FURFARO, 2012).

Outros programas relacionados com a eficiência energética no setor residencial são:

1. Certificação energética de prédios: consumos máximos e mínimos de energia elétrica e térmica.
2. Programa relacionado com o uso ótimo da energia solar em prédios comerciais e residenciais.

3. Programa de implementação de sistemas de aquecimento de água baseados na energia solar.
4. Programa Nacional de isolamento de domicílios.

b) Chile

No Chile, o consumo de energia elétrica no setor residencial, representou 22% do consumo total por setor, em 2010. A mineração, juntamente com a indústria, consome 37% do consumo total de energia elétrica do país. A média da taxa de crescimento do setor residencial de 2000 a 2010, foi de 1,2%. O consumo residencial está dividido em aquecimento de residências (56%); aparelhos elétricos (16%); aquecimento de água (18%) e cozimento (10%) (MIN-CHILE, 2017).

O estudo “*Curva de Conservación de Energia del Sector Residencial*” (ROMERO RAMOS, 2011) caracterizou e analisou o consumo de energia elétrica no setor residencial. Para esse estudo foram feitas entrevistas em mais de 3.200 domicílios, distribuídos nas 7 áreas climáticas do país, com um intervalo de confiança de 95% da amostra. Entre os resultados, identificou-se que os aparelhos que mais consomem energia elétrica, em ordem decrescente, são: geladeiras e freezers (30%); iluminação (16%); televisão (12%); aspirador de pó (5%).

Programas de EE

1. Sistema Nacional de Etiquetagem: esse programa começou em 2007, com foco em geladeiras e lâmpadas.
2. Plano de ação de Eficiência Energética (PAEE) até 2020. Nesse plano de EE suas principais ações são redução do consumo energético de prédios, focado na EE de iluminação, térmica e de ventilação; gestão do consumo energético em prédios de grande porte; promoção de produtos e serviços no setor da construção; e, finalmente, implementação da EE em iluminação de estradas e em áreas pedestres urbanas (PPEE, 2017).

c) Uruguai

O sistema energético uruguaio baseia-se principalmente em quatro fontes: eletricidade, combustíveis líquidos, biomassa e gás natural, sendo que, em 2006, a eletricidade teve uma

participação de 63% do total de energia consumida. No Uruguai, o consumo final no setor residencial está distribuído na seguinte proporção: aquecimento de domicílios (19%); aparelhos elétricos (37%); aquecimento de água (20%); cozimento (18%) e ar-condicionado (6%) (AGOSTINI; SAAVEDRA; PLOTTIER, 2011).

Programas de EE

Os programas de EE feitos no Uruguai são principalmente educacionais, focados na mudança dos hábitos das pessoas. Os principais programas que merecem destaque são:

1. Programa nacional de padronização e etiquetagem, implementado a partir de 2006, para aparelhos de uso doméstico e industrial.
2. Normas para avaliação do desempenho energético em 5 grupos de eletrodomésticos: refrigeração e iluminação; eletrodomésticos que operam com gás; aquecedores térmicos; prédios e veículos leves.
3. Programa de laboratórios para avaliar aparelhos com selo de EE.
4. Introdução de novas tecnologias no mercado, tais como LED e sistemas de aquecimento solar.

d) Alguns resultados numéricos dos planos de EE desenvolvidos na América Latina

A seguir são apresentados alguns resultados de programas de EE executados na América Latina. Vale a pena ressaltar que as informações ainda são escassas e pouco difundidas nos países da região:

1. No Brasil, a partir de 1985, passa a existir o *Programa Nacional para a Conservação da Energia Elétrica - PROCEL* (HORTA NOGUEIRA, 2010), cujo objetivo é a promoção da produção racional de energia elétrica e de seu uso eficiente. Os investimentos entre 1986 e 2005 foram de 461 milhões de dólares, proporcionando uma economia de energia na geração de cerca de 5 MW.
2. Os resultados nos programas de eficiência energética em relação às geladeiras, no Brasil, mostraram que, em 2006, existiam aproximadamente 49 milhões de geladeiras, com uma entrada anual de 4 milhões de geladeiras novas, das quais 2 milhões eram de alta eficiência. Em 2008, adicionaram-se 4,82 milhões de geladeiras novas. Uma estimativa da PROCEL, em 2005, calculou que a economia de energia foi de 1.058

GWh, o que foi equivalente a uma redução da capacidade instalada de 151 MW. As metas totais contempladas no plano de EE, no Brasil, visavam à substituição de um total de 10 milhões de geladeiras, em um prazo de 10 anos (PROCEL, 2005).

3. No Peru, o *Centro de Conservación de la Energía y el Ambiente-CENERGIA*⁶, que opera desde 1985, é um organismo com participação mista (público e privada), que desenvolveu mais de 300 estudos e projetos de EE e de conservação do meio ambiente.
4. Em relação à substituição de lâmpadas incandescentes por lâmpadas fluorescentes compactas, a quantidade de lâmpadas substituídas em função da população do país, em ordem decrescente, foi de 1 lâmpada por habitante, no Brasil; 0,65 lâmpadas por habitante, na Argentina; 0,4 lâmpadas por habitante, no Peru; 0,35 lâmpadas por habitante, na Colômbia; e 0,3 lâmpadas por habitante, no Chile (HORTA NOGUEIRA, 2010). Essas ações fizeram com que houvesse redução de 15% na demanda máxima de ponta, em relação ao consumo de energia elétrica exclusivamente por uso de lâmpadas (BARILOCHE; INGENIEROS, 2007). A economia de energia obtida por meio dos planos de substituição de lâmpadas foi estimada em 9.151 GWh/ano, no Brasil; 2.486 GWh/ano na Venezuela; 2.048 GWh/ano, na Argentina; 508 GWh/ano, no Peru; e 416 GWh/ano, na Colômbia.
5. Em relação às geladeiras, trata-se de um eletrodoméstico mais complexo (HORTA NOGUEIRA, 2010), de maior uso e com um consumo que se aproxima de um terço do consumo total do domicílio, sendo que a tecnologia é um fator muito importante no consumo de energia. Vale destacar que, nas últimas duas décadas, houve melhorias na EE desses aparelhos, que permitiram reduções de quase metade do consumo, mantendo a mesma capacidade de refrigeração. Esse fato é resultante de políticas de EE, principalmente do uso de etiquetas de eficiência, sendo Brasil, México e Cuba, os países líderes na América Latina (HORTA NOGUEIRA, 2010).
6. No México, entre 1995 e 2005, foram vendidas aproximadamente 16 milhões de geladeiras. Fazendo uma estimativa geral, a substituição dessas geladeiras resultou em uma economia de energia de 29.290 GWh, o que foi equivalente a uma redução de 1.057 MW da capacidade instalada. Em Cuba, também entre 1995 e 2005, 2,5 milhões de geladeiras foram substituídas. Em uma estimativa geral, essa substituição gerou uma economia de energia de 4.750 GWh, o que correspondeu a uma redução de 165 MW da capacidade instalada

⁶ Centro de Conservación de la Energía y el Ambiente - CENERGIA. Informações disponíveis no site <www.cenergia.pe>

(SANCHEZ *et al.*, 2007).

2.3 Programas de Eficiência Energética: Experiência Brasileira

O consumo de energia elétrica total, em 1990, foi de 217.657 GWh e, em 2014, foi de 522.833 GWh. Esse crescimento representou um incremento de 1,34 vezes no consumo entre esses anos (EPE, 2015). Com relação ao consumo no setor residencial, em 1990, o consumo era de 48.666 GWh, enquanto, em 2015, era de 131.315 GWh, representando um aumento de 1,62 vezes no consumo de eletricidade no setor residencial (EPE, 2015). Essas mudanças mostram o impacto no consumo de energia elétrica no setor residencial, o qual pode ser explicado por quatro razões principais: (i) substituição de energéticos (biomassa e petróleo) (TOLMASQUIM, 2012); (ii) aumento na compra de eletrodomésticos a partir de 1994 (DE PAULA FALCO, 2010); (iii) maior crescimento do consumo entre 2001 e 2012, com uma taxa média anual de 4.1%; e (iv) aumento dos domicílios – estima-se que a quantidade de moradias cresceu 77% no período de 1990 a 2010 (IBGE, 2010). No Brasil, destacam-se os seguintes programas de EE no setor residencial.

a) Programas de Eficiência Energética da ANEEL (PEEA)

No Brasil, os PEEAs são regulados pela Agência Nacional de Energia Elétrica (ANEEL). A partir de 1998, nos contratos de concessão firmados entre as concessionárias do serviço público de distribuição de energia elétrica e a ANEEL, passou a ser obrigatório que as concessionárias desenvolvessem PEEs da ANEEL. A Lei Federal 9.991 de 2000 (LEI 9.991, 2000), obrigou as empresas concessionárias de energia elétrica a investir, anualmente, 0,5% da receita operacional líquida em ações de EE. Desses investimentos, 70% devem ser destinados aos consumidores de baixa renda, que recebem subsídio na tarifa de energia elétrica.

A Resolução Normativa 300 de 2008 (ANEEL, 2008) criou os procedimentos dos PEE da ANEEL. O objetivo principal desses PEEs é promover o uso eficiente e racional de energia elétrica, em todos os setores da economia, por meio de projetos que demonstrem a importância e a viabilidade econômica de ações de combate ao desperdício, bem como demonstrem o aumento da EE de equipamentos, processos e usos finais de energia.

Para determinar a eficácia dos PEEs da ANEEL, foram criados os processos de Medição e Verificação - M&V, que determinam a economia de energia dentro de uma residência, fábrica ou instalação por meio de um programa de gestão de energia. A economia é determinada comparando o consumo medido antes e depois da implementação do projeto. A aplicação do M&V é feita baseada no Protocolo Internacional para Medição e Verificação de Performance – PIMVP (POMPERMAYER, 2012). Nesse protocolo, aplicam-se as seguintes atividades: (i) documentação de termos comuns e métodos para avaliar o desempenho energético de projetos de eficiência; (ii) fornecimento de métodos, com diferentes níveis de custo e exatidão; e (iii) especificação do conteúdo de um plano de M&V.

No período compreendido entre 2008 e dezembro de 2015, foram feitos 434 PEEs da ANEEL, em comunidades de baixa renda. A economia de energia resultante desses projetos foi de 2.337 GWh/ano e a demanda retirada de ponta foi de, aproximadamente, 888 MW. Os investimentos totais nesses PEEs foram de 2.660 milhões de reais. Na Figura 2.3, apresenta-se a distribuição de todos os PEEAs realizados pelo Brasil, desde o começo do ProPEE até dezembro de 2015. Observa-se na Figura 2.3, que projetos em comunidades de baixa renda representam apenas 27% do total de projetos executados. Entretanto, os mesmos representam quase 60% dos investimentos totais dos PEEs da ANEEL (PEE-ANEEL, 2016).

Em relação ao uso final nos PEEs da ANEEL, entre 2008 e dezembro de 2015, nas comunidades de baixa renda, foram aplicados PEEs em aparelhos de uso residencial para o aquecimento de água do banho, iluminação, refrigeração, entre outros. No total, 17,4% dos PEEs foram aplicados em aquecimento de água, principalmente na substituição de chuveiros elétricos; 42,8% foram aplicados em iluminação, para substituição de lâmpadas; 31,8% foram aplicados na substituição de geladeiras; e 8% foram aplicados em outros tipos de aparelhos.




Figura 2.3 - Porcentagens dos PEEAs desde o começo do ProPEE até dezembro de 2015.
Fonte: Dados da ANEEL dos PEEs (PEE-ANEEL, 2016).

De modo geral, os PEEAs permitiram a participação de mais de 45 concessionárias de distribuição de energia elétrica em comunidades de baixa renda. De acordo com a ANEEL, foi investido um total de 5,7 bilhões de reais, o equivalente a 1,85 bilhões de euros, entre 1998 e março de 2014⁷. Por meio dos PEEAs, entre 1998 e 2012, obteve-se uma economia de energia de 8,5 TWh/ano e uma demanda retirada de ponta de 2,5 GW. Segundo o Ministério de Minas e Energia (MME), traçou-se o objetivo de reduzir 10% da demanda estimada com a aplicação dos PEEs (PPEE, 2014).

b) Como é desenvolvido um PEE da ANEEL

O PEE é planejado pelas concessionárias com base nas resoluções aprovadas pela ANEEL e orientações contidas no Manual Para Elaboração do Programa de Eficiência Energética (ProPEE). Este manual apresenta, passo a passo, como a concessionária de energia elétrica deverá elaborar o PEE (ProPEE – ANEEL, 2008).

⁷ Measurement & Verification on the Brazilian Energy Efficiency Program. informações disponíveis no site <<https://www.giz.de/en/downloads/giz2015-en-energy-efficiency-measurement-brasilien.pdf>>

A partir de 2008, a ANEEL tornou obrigatória a realização de M&V para avaliar os impactos efetivos das ações de EE sobre o consumo de eletricidade e a demanda retirada na ponta. O órgão regulador estabelece que as atividades de M&V devem ser baseadas no PIMVP. Tendo isso em vista, há atualmente um estoque importante de medições de usos finais decorrente dessas atividades de M&V (GOMES *et al.*, 2013). Independentemente da qualidade dos dados, é importante que essas informações estejam disponíveis de uma maneira organizada.

Para a seleção das famílias que fazem parte dos PEEs, o programa é regulado pela Lei Federal 10.438 de 2002 (LEI 10.438, 2002) e os descontos são regulamentados pela Resolução Normativa ANEEL 485 de 2002 (ANNEEL, 2002), reformulada pela resolução normativa 407 de 2010 (ANEEL, 2010), sendo necessário que a família atenda pelo menos a um dos critérios enumerados a seguir.

- Estar inscrita no Cadastro Único⁸, com renda familiar *per capita* de até meio salário mínimo, baixa renda NIS.
- Ter algum morador na unidade consumidora que receba o Benefício de Prestação Continuada da Assistência Social (BPCAS). Pago pelo Governo Federal e assegurado por Lei, o benefício permite o acesso de idosos e de pessoas com deficiência às condições mínimas de uma vida digna⁹.
- Excepcionalmente, famílias inscritas no Cadastro Único, com renda mensal de até três salários mínimos que tenham, entre seus membros, pessoas em tratamento de saúde e que estejam internadas em casa e necessitem usar continuamente equipamentos hospitalares, com elevado consumo de energia.
- As famílias indígenas e quilombolas inscritas no Cadastro Único com renda familiar *per capita* menor ou igual a meio salário mínimo, ou que possuam, entre seus moradores, algum beneficiário do BPC, terão direito ao desconto de 100% na conta de luz até o limite de consumo de 50 kWh/mês (LEI 12.2012, 2010).

⁸ O Cadastro Único para Programas Sociais do Governo Federal (NIS) é um instrumento que identifica e caracteriza as famílias de baixa renda, entendidas como aquelas que têm renda mensal de até meio salário mínimo por pessoa ou renda mensal total de até três salários mínimos.

⁹ Possui o direito de receber o benefício, pessoa idosa com 65 anos de idade ou mais, que não recebe nenhum benefício previdenciário ou de outro regime de previdência e que a renda mensal familiar *per capita* seja inferior a ¼ do salário mínimo.

c) Programa Brasileiro de Etiquetagem

O Instituto Nacional de Metrologia, Qualidade e Tecnologia (INMETRO), juntamente com o CONPET, desenvolveram o Programa Brasileiro de Etiquetagem, primeiramente aplicado em equipamentos que consomem combustíveis (INMETRO, 2016). Na Etiqueta Nacional de Conservação de Energia (ENCE), a classificação vai da letra A – equipamento mais eficiente, até a letra E – equipamento menos eficiente. Atualmente, a etiquetagem é também usada nos aparelhos elétricos de uso residencial (INMETRO, 2016), tais como aquecedores elétricos, chuveiros elétricos, condicionadores de ar, lâmpadas de uso doméstico e lavadoras.

Em 1993, foi instaurado o selo Procel (INMETRO, 2016). Esse selo tem por objetivo orientar o consumidor na compra de eletrodomésticos, em relação aos equipamentos de melhores níveis de eficiência energética; outro objetivo do selo também é contribuir com o desenvolvimento tecnológico de equipamentos mais eficientes e que causem menor impacto ao meio ambiente.

De acordo com os resultados da PROCEL, em 2014, foram vendidos mais de 59 milhões de equipamentos (em geral eletrodomésticos de uso residencial). Esse programa ajudou a economizar aproximadamente 10 TWh. Além disso, permitiu a redução da demanda no horário de ponta em 4.009 MW aproximadamente. A título de exemplificação, com o selo PROCEL reduziu-se o consumo de energia elétrica em refrigeradores de 1 porta, passando de 28,2 kWh/mês, no ano 2000, para 23 kWh/mês, em 2014, o que corresponde a uma redução percentual de 18,4%. No que diz respeito a geladeiras que incluem freezer, o consumo de energia elétrica no ano 2000 foi de 68,3 kWh/mês, passando para 52,9 kWh/mês, em 2014, o que corresponde a uma redução de 22,6%.

Entre os resultados obtidos do selo PROCEL, entre 2005 e 2012, a posse de geladeiras aumentou de 87,9% a 94,5%, nas famílias brasileiras. Esse incremento na posse de equipamentos contribuiu com um aumento no consumo de 1.402 GWh. Entretanto, os ganhos na eficiência energética com o uso de geladeiras mais eficientes (Selo PROCEL), compensou esse incremento com 1.119 GWh em economia de energia. Em relação às máquinas de lavar roupa, o aumento de posse contribuiu com um aumento no consumo de 262 GWh. Em relação ao uso de lavadoras mais eficientes (Selo PROCEL), a economia de energia foi de 200 GWh.

d) Lei de Eficiência Energética

No ano 2001 foi criada a Lei nº 10.295, conhecida como a Lei de Eficiência Energética (EE). A lei visa a alocação eficiente de recursos energéticos e a preservação do meio ambiente. Para implementar a lei, foi estabelecido um comitê formado pelos diferentes setores relacionados com a EE, incluindo o Ministério de Minas e Energia, o Ministério da Ciência, o Ministério da Tecnologia e Inovação, a ANEEL, e a Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP), além de um representante da universidade e um cidadão brasileiro. Nesse comitê são estabelecidos os níveis máximos de consumo específico de energia e mínimos de eficiência energética, de máquinas e aparelhos consumidores de energia fabricados ou comercializados no País.

São diversos os programas implementados a partir da Lei de EE, com destaque para a regulamentação dos equipamentos elétricos com o Selo Procel; o estabelecimento dos padrões mínimos de eficiência ou máximos de consumo; a regulamentação de outros energéticos, principalmente com derivados do petróleo com o Selo CONPET; além da regulamentação de edificações eficientes. Destacam-se, também, os programas PROCEL de educação. Esse programa tem por objetivo ampliar o conhecimento sobre energia e eficiência energética, tornando-o acessível à população brasileira. O programa envolve instituições públicas e privadas, incluindo secretarias de educação, escolas técnicas e universidades, nos diversos níveis escolares.

2.4 Métodos de projeção da demanda

As abordagens para projetar a demanda de energia podem ser classificadas em duas categorias principais; os métodos *Top-Down* e os métodos *Bottom-Up* (SWAN; UGURSAL, 2009; GRANDJEAN; ADNOT; BINET, 2012). A abordagem *Top-Down* geralmente emprega informações macroeconômicas, como Produto Interno Bruto (PIB), população, consumo de eletricidade e outras variáveis relacionadas com países, cidades e regiões (SHARMA; NAIR; BALASUBRAMANIAN, 2002; BAJAY, 1983; SOARES; MEDEIROS, 2008). Essa abordagem, frequentemente se baseia em métodos econométricos e estatísticos para previsão da demanda. Em contraste, a abordagem *Bottom-Up* é um método desagregado, que se foca no consumo energético na base. Na abordagem *Bottom-Up* é comum usar dados referentes ao

consumo desagregado dos setores energéticos (comercial, transporte, residencial e industrial). Alguns especialistas na área consideram esse tipo de modelagem, uma abordagem de engenharia (REMME *et al.*, 2002). Outro aspecto que merece destaque, é a possibilidade da abordagem *Bottom-Up* capturar informações referentes às tecnologias dos aparelhos e as mudanças tecnológicas (RICHARDSON; THOMSON; INFELD, 2008 ; HILLER, 2012 ; FIRTH *et al.*, 2008).

Na Figura 2.4 se apresenta uma visão geral da abordagem *Bottom-Up*. Nessa figura, mostra-se que o consumo de energia do setor residencial pode ser calculado usando dois enfoques, o estatístico e o de engenharia. Na abordagem estatística, há três possibilidades de modelagem: regressões, análise da demanda condicional ou técnicas de Inteligência Artificial (IA) (FUMO, 2014; KIALASHAKI; REISEL, 2013; HERBST *et al.* 2012). No que diz respeito às regressões, o enfoque é diferente do da abordagem *Top-Down*, visto que há regressões baseadas, principalmente, nas variáveis técnicas, tais como radiação solar e velocidade do vento (KAVGIC *et al.*, 2010 ; FLEITER; WORRELL; EICHHAMMER, 2011). Por último, o enfoque baseado na computação flexível é baseado em técnicas como a lógica *Fuzzy*, os Algoritmos Genéticos (AG), ou as RNAs (SUGANTHI; SAMUEL, 2012 ; FOLEY *et al.* 2010).

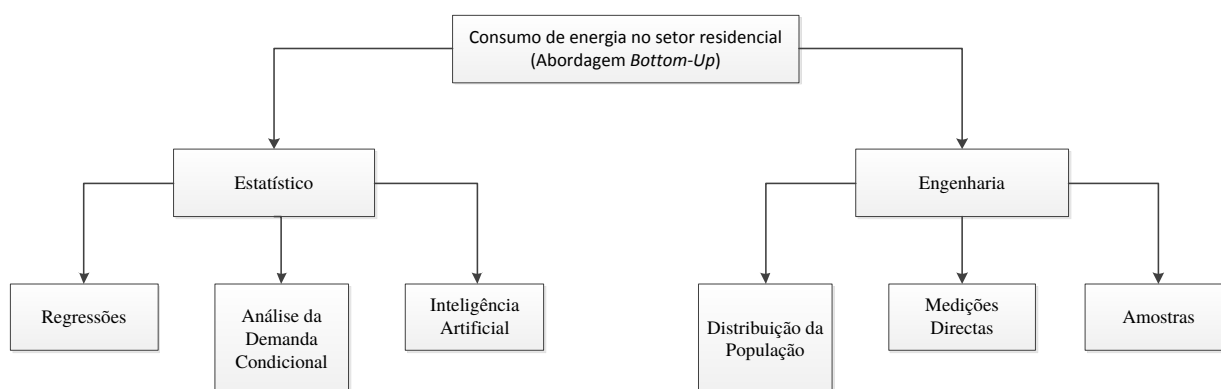


Figura 2.4 - Visão geral da abordagem *Bottom-Up*.

Fonte: Classificação de modelos de energia, Adaptado de Van Beeck (1999).

Diante dos muitos trabalhos desenvolvidos na área de EE no setor residencial, na Tabela 2.1, são apresentados alguns estudos baseados na abordagem *Bottom-Up*, que contêm análises detalhadas do consumo de energia elétrica a partir de medições. O projeto *Canadian Residential Energy End-Use Model* (CREEM), conta com uma base de posse de equipamentos e de emissões de CO₂, a partir de medições no Canadá. No total foram medidas 8.677 residências, o objetivo desse projeto foi avaliar o impacto das políticas energéticas na redução do consumo de energia no setor residencial (FARAHBAKHS; UGURSAL; FUNG, 1998).

No Reino Unido, o projeto *Building Research Establishment* (BRE) contêm uma base de medições realizadas durante vários anos, relacionadas com a posse de equipamentos, o consumo de energia e as emissões CO₂. Com os dados históricos, foram elaboradas possíveis tendências de EE, a partir das mudanças tecnológicas nos equipamentos (SHORROCK; DUNSTER, 1997). Outro projeto desenvolvido no Reino Unido, focado no consumo de energia elétrica em prédio comerciais, integrou quatro importantes aspectos: (i) gestão de políticas organizacionais e regulatórias; (ii) posse de equipamentos elétricos; (iii) comportamento humano; e (iv) consumo de energia elétrica nos prédios (NATARAJAN; PADGET; ELLIOTT, 2011). Ainda no Reino Unido, o projeto *Community Domestic Energy Model* (CDEM) estudou os potenciais de redução de emissões por equipamentos, sejam aparelhos elétricos, iluminação, aquecimento domiciliar ou aquecimento de água (FIRTH; LOMAS; WRIGHT, 2010).

Na Califórnia, EUA, um projeto desenvolvido pelo Departamento de Energia estimou o consumo de equipamentos de resfriamento e aquecimento, entre 1986 e 1992. No estudo, participaram 112 residências, 66 condomínios e 481 prédios comerciais. O estudo permitiu determinar possibilidades de economia de energia usando outros tipos de isolamentos nos prédios, além de determinar cenários de EE (HUANG; BRODRICK, 2000).

Tabela 2.1 - Alguns estudos baseados na abordagem *Bottom-Up*.

Projeto	Ano	Nível de desagregação	Objetivo	Localização
CREEM	1998	8.767 Residências	Medição e análise do consumo de energia elétrica	Canadá
BRE	1999	1.000 Residências	Medição e análise do consumo de energia elétrica	Reino Unido
<i>A Bottom-Up Engineering Estimate of the Aggregate Heating and Cooling Loads U.S Building Stock</i>	2000	112 Residências, 66 condomínios e 481 prédios comerciais.	Medição e análise do consumo de energia com aquecimento e refrigeração	Estados Unidos
UKDCM	2006	20.000 Residências (em desenvolvimento)	Medição e análise do consumo de energia elétrica e emissões, mensalmente	Reino Unido
CDEM- The Community Domestic Energy Model	2009	47 diferentes tipos de residência	Medição e análise do consumo de energia elétrica e emissões mensalmente	Reino Unido

Fontes: Estudo CREEM (FARAHBAKHSH; UGURSAL; FUNG, 1998); estudo BRE (SHORROCK; DUNSTER, 1997); estudo *Heating and Cooling Loads U.S Building Stock* (HUANG; BRODRICK, 2000); estudo UKDCM (NATARAJAN; PADGET; ELLIOTT, 2011); e o estudo CDEM (FIRTH; LOMAS; WRIGHT, 2010).

Além dos trabalhos mencionados na Tabela 2.1, outros trabalhos recentes, relacionados com medições e que seguem a abordagem *Bottom-Up*, são discutidos brevemente a seguir. No projeto EURECO¹⁰, foram feitas medições em 400 domicílios na Europa. A base de dados do EURECO contém medições do consumo de aparelhos elétricos em residências. Nesse projeto, foi feita uma completa caracterização do consumo de equipamentos elétricos, tais como televisores e computadores (BORG; KELLY, 2011).

Stokes (2005), em sua tese de doutorado, analisou o impacto de cargas na rede elétrica, através da modelagem dos equipamentos elétricos residenciais e da construção da curva de

¹⁰ Base de dados. REMOCEDE. Informações disponíveis no site <http://remodece.isr.uc.pt/database/Campaign_Eureco.htm>

carga média das medições feitas. No trabalho de Richardson *et al.* (2008), foi desenvolvida a curva de carga média dos eletrodomésticos nas residências medidas. Além disso, foi feita uma modelagem detalhada da demanda de energia elétrica, focada no consumo de cada aparelho elétrico residencial. Outro trabalho relacionado com a construção da curva de carga horária, usando a *Bottom-Up*, foi feito por Hainoun (2009). O autor fez uma previsão da demanda de energia para o ano 2030, nos setores residencial, industrial, de transporte e de serviços, para o sistema interligado da Síria.

Dentre os artigos recentes da área, destaca-se o trabalho de McNeil *et al.* (2013), que inclui 16 classes de equipamentos, em 11 países. O trabalho analisa o impacto das políticas de eficiência energética para iluminação, aquecimento, ventilação e ar-condicionado nas residências. Gram-Hanssen (2013) escreveu um artigo que avalia o impacto das tecnologias e do comportamento dos consumidores na eficiência energética nos domicílios da Dinamarca.

Greenblatt *et al.* (2013) realizou um trabalho com dados em geladeiras e freezers da cidade de New York para determinar a curva de carga. Nesse estudo, foram usados dados da energia consumida em 1.467 geladeiras e 185 freezers entre 1992 e 2005.

2.4.1 Métodos de previsão de carga de curto prazo

Os métodos de previsão de carga estão divididos em três categorias principais, de acordo a sua duração (LEE; LEE; CHANG, 1997): (i) curto prazo (HIPPERT; PEDREIRA; SOUZA, 2001) (SZKUTA; SANABRIA; DILLON, 1999) (de uma hora a uma semana); (ii) médio prazo (de uma semana a um ano) e, (iii) longo prazo (previsão superior a um ano) (KANDIL; EL-DEBEIKY; HASANIEN, 2002) (CHOW; WU; MOMOH, 2005).

Existem diversos trabalhos baseados na computação flexível, para determinar a curva de carga com erros de previsão mais baixos em comparação aos métodos tradicionais (BADRI; AMELI; BIRJANDI, 2012; MANDAL *et al.* 2006; LIAO; TSAO, 2004; WARWICK, 1997). Uma das técnicas usadas é a lógica *Fuzzy*, que tem sido amplamente usada (PANDIAN *et al.* 2006; AL-KANDARI; SOLIMAN; EL-HAWARY, 2004). Por exemplo, Bakirtzis *et al.* (1995) desenvolveram uma aplicação *Fuzzy* para determinar a demanda de energia elétrica a curto prazo.

Por sua vez, Senjyu *et al.* (1998) propuseram uma previsão da curva de carga no próximo dia. Pandian *et al.* (2006), empregaram a lógica *Fuzzy* na previsão de carga e

obtiveram resultados muito próximos aos obtidos pelos métodos tradicionais. Mamlook *et al.* (2009) exploraram o uso de variáveis não tradicionais, tais como a temperatura, o tipo de dia (ensolarado, chuvoso e outras condições climáticas). Além disso, Mamlook (2006) propôs uma metodologia para avaliar alternativas entre diferentes sistemas de energia.

Outra alternativa na previsão de curvas de carga são as RNAs. As RNAs são ferramentas flexíveis na modelagem, especialmente em sistemas não lineares (MOHAMAD *et al.* 1996). Um dos aspectos mais difíceis e complexos das RNAs, é a determinação da arquitetura a ser usada, e a determinação dos pesos associados nas camadas de neurônios (PAPALEXOPOULOS; HAO; PENG, 1994; KHOTANZAD; AFKHAMI-ROHANI; MARATUKULAM, 1998). Na literatura científica, existe um número amplo de trabalhos na previsão das curvas de carga usando as RNAs (BENEDETTI *et al.* 2016; BALIYAN; GAURAV; MISHRA, 2015; BARUNÍK; MALINSKA, 2016).

Uma das alternativas existentes na previsão das curvas de carga é a modelagem dos hábitos dos consumidores. Os hábitos dos consumidores são um conceito amplo e difícil de definir. No entanto, na literatura científica são vários os esforços feitos para modelar os hábitos dos consumidores e obter a curva de carga. Um primeiro esforço foi feito por Walker e Pokoski (1985). Estes autores desenvolveram uma curva de carga diária, a partir dos fatores psicológicos dos consumidores, usando funções de probabilidade que modelam o uso dos aparelhos eletrodomésticos. Michalik *et al.* (1997) fizeram um modelo estrutural para o consumo de energia no setor residencial, diferenciando o consumo pelos tipos de usuários residenciais. Zúñiga *et al.* (2014) determinaram a curva de carga para máquinas de lavar, estufas e lâmpadas, usando lógica *Fuzzy* com dados sobre os hábitos dos consumidores, provenientes do Instituto Nacional de Estatística¹¹ (2015).

¹¹ Site <http://www.ine.es/>

3 METODOLOGIA PARA A PREVISÃO DE CURVAS DE CARGA NOS CHUVEIROS ELÉTRICOS, USANDO AS ABORDAGENS SIF E RNA

Neste capítulo é apresentado o desenvolvimento metodológico das abordagens *Fuzzy* e RNA para a previsão de curvas de carga de CEs. Uma visão geral das etapas metodológicas aplicadas é mostrada na Figura 3.1, usando um fluxograma. As cinco etapas metodológicas e procedimentais para obtenção das curvas de carga são: (i) obtenção dos dados (etapa 1); (ii) tipos de tecnologias de CE usados nos PEEs da ANEEL (etapa 2); (iii) métodos de previsão empregando as abordagens *Fuzzy* (etapa 3) e RNA (etapa 4); e (iv) validação do EAM e do EMPA (etapa 5).

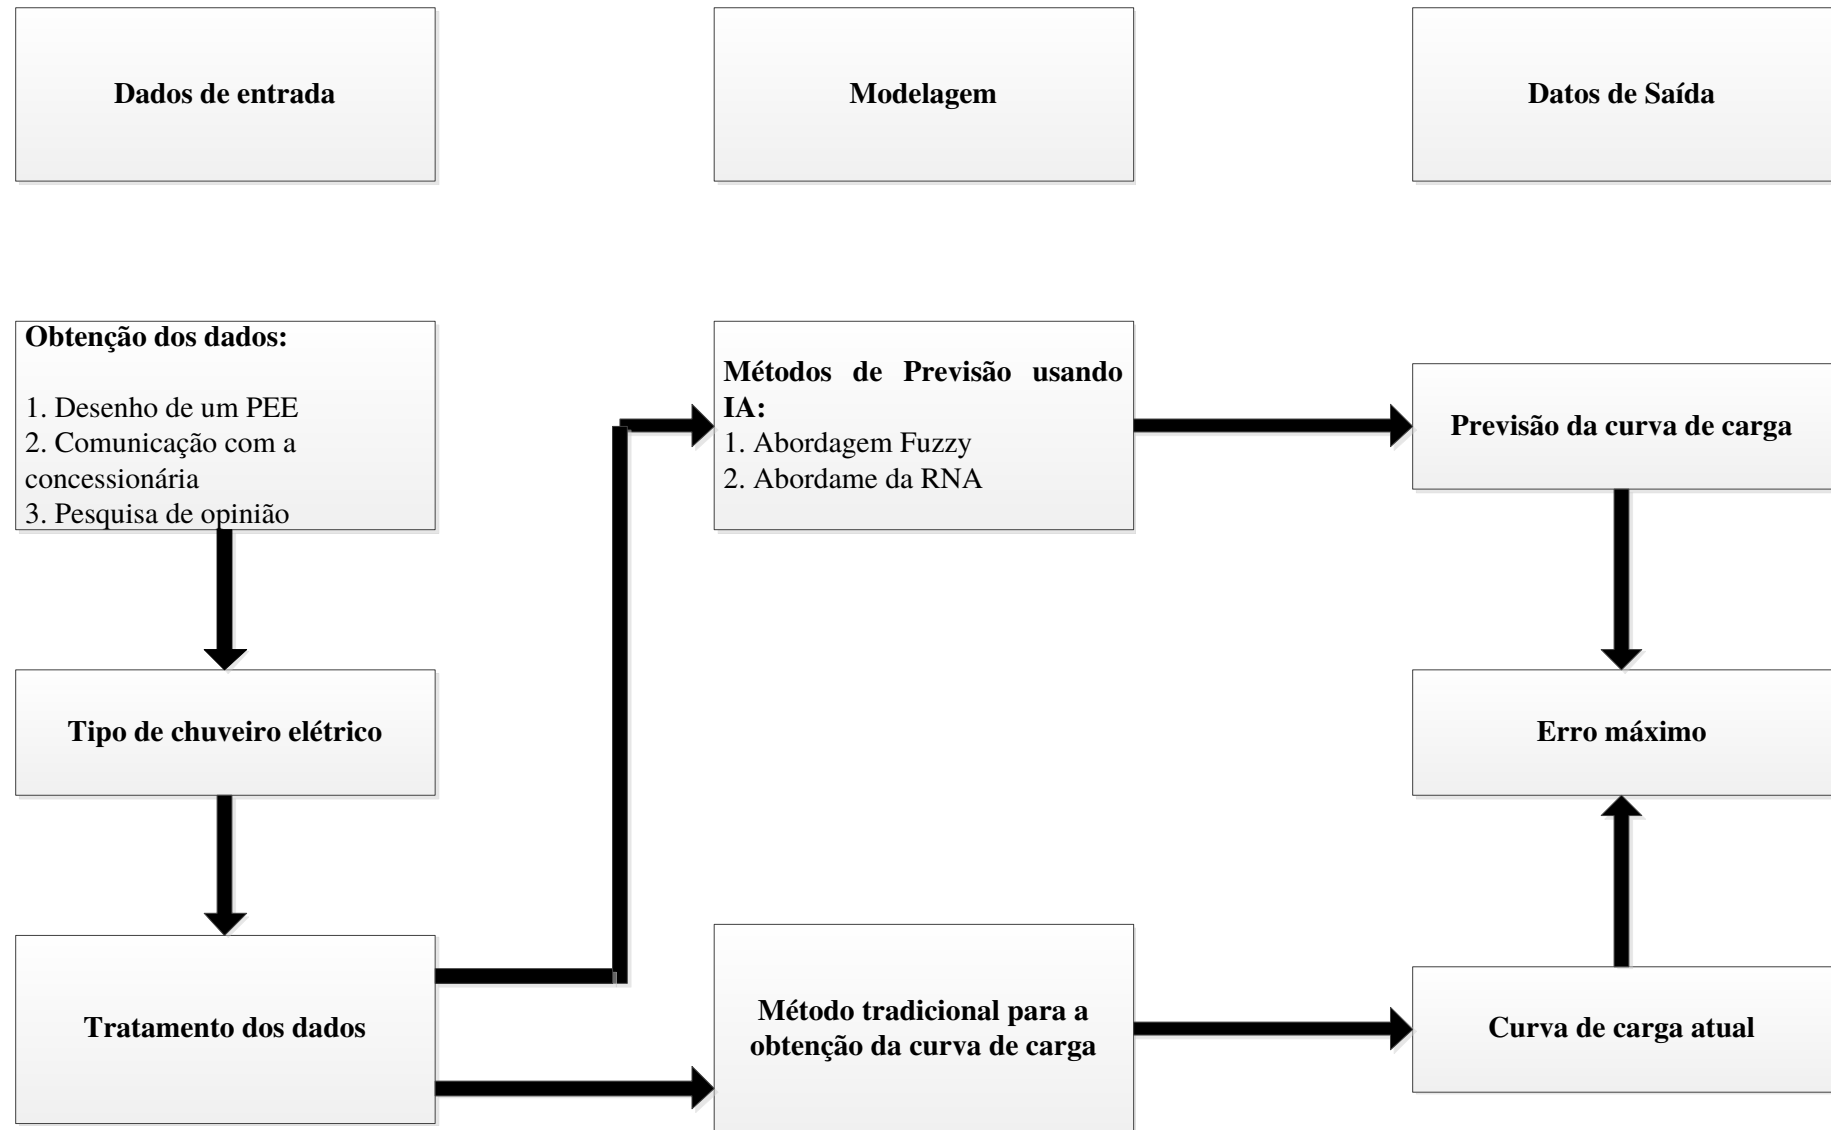


Figura 3.1- Fluxograma metodológico para a previsão das curvas de demanda nos CE, usando a lógica *Fuzzy* e as RNAs.

3.1 Obtenção dos dados (PEEs da ANEEL) – Etapa 1

Para a seleção das famílias de baixa renda que fazem parte dos PEEs da ANEEL, leva-se em conta a Lei 10.438 de 2002 (LEI 10.438 de 2002). Entre os equipamentos mais usados nesses PEEs da ANEEL, encontram-se as geladeiras, os CEs e as lâmpadas. A metodologia desenvolvida na tese restringiu-se a CEs. Não obstante ela pode ser aplicada para outros equipamentos.

Para cada unidade de moradia é feito o seguinte procedimento logístico: (i) pedido de equipamentos para troca; (ii) emissão e assinatura dos termos do PEE; e (iii) substituição de geladeiras e de lâmpadas e troca de chuveiros.

Para obtenção dos dados na metodologia, há três possibilidades: (i) desenho de um PEE que inclua a seleção e medição das moradias; (ii) obtenção dos dados a partir de comunicação com a concessionária de energia elétrica; ou (iii) a partir de pesquisas de opinião.

3.1.1 Desenho de um PEE

Um PEE é um projeto que vai ser selecionado por meio de uma chamada pública ou atribuído diretamente à distribuidora pela ANEEL. Um PEE, de acordo com o ProPEE (ProPEE - ANEEL, 2008), contém as seguintes etapas, uma vez que o projeto seja desenvolvido pela distribuidora.

1. Definição do projeto (PEE)
2. Carregamento do projeto no Sistema de Gestão do PEE (SGPEE)
3. Início do projeto
4. Validação da M&V
5. Relatório final

Uma vez que sejam realizadas as três primeiras etapas do PEE, continua-se com a etapa de validação do PEE mediante a M&V. Nesta etapa de M&V, para a validação do cumprimento dos objetivos do PEE, aplicam-se as ações descritas abaixo.

a) Amostra

Nos PEEs da ANEEL implementados nas comunidades de baixa renda, as ações de M&V serão feitas por amostragem e seleção aleatória das unidades consumidoras. Na Tabela 3.1 é apresentado o número de unidades consumidores que devem ser medidas para validação, de acordo com a norma NBR 5926.

Tabela 3.1 - Tamanho da amostra de acordo com a ProPEE-ANEEL 2008, nos PEEs da ANEEL de baixa renda no Brasil.

Número de unidades consumidoras	Tamanho da amostra (regime severo, nível 1)
2 a 8	A=2
9 a 15	A=2
16 a 25	B=3
26 a 50	C=5
51 a 90	C=5
91 a 150	D=8
151 a 280	E=13
281 a 500	F=20
501 a 1200	G=32
1201 a 3200	H=50
3201 a 10000	J=80
10001 a 35000	K=125
35001 a 150000	L=200
150001 a 500000	M=315
Acima de 500000	N=500

Fonte: Procedimentos do Programa de Eficiência Energética (ProPEE - ANEEL, 2008)

Uma amostra em termos estatísticos pode ser (i) uma amostra probabilística, que se refere a uma seleção aleatória das residências em uma área geográfica selecionada, ou (ii) uma amostra estratificada, que se refere a uma classificação das residências a partir de fatores econômicos ou sociais. Nesse sentido, alcançar uma amostra totalmente probabilística em alguns casos resulta muito difícil por várias razões, tais como interesse dos moradores de participar nos PEEs da ANEEL, problemas de logística ou questões sociais e econômicas que possam surgir nas comunidades ou no programa.

Para determinar o número das amostras a partir do intervalo de confiança, pode-se utilizar a equação (1). Esta é uma equação útil no cálculo da amostra baseado no número das residências medidas (CREATIVE RESEARCH SYSTEMS, 2016).

$$n = \left(\frac{S * 2 * Z_{\frac{\alpha}{2}}}{L} \right)^2 \quad (1)$$

Onde:

n: Número de residências medidas.

S: Desvio padrão.

Z_{α/2}: Valor Z, que depende da distribuição e do intervalo de confiança

L: Intervalo de confiança

Neste tipo de estudos, o ideal seria ter estimativas com 95% de confiabilidade e precisão de 5%. Entretanto, o acréscimo de uma unidade na amostra do universo, traz impacto considerável aos custos e à logística envolvidos no PEE. Por essa razão, o Guia de M&V recomenda manter o intervalo de confiança de 95%, porém com uma precisão de 10%.

b) Medições

As medições deverão ser baseadas no PIMVP, que contém um guia para fazer as medições e determinar o impacto do M&V nos projetos da ANEEL. De acordo com o Manual do Programa de EE da ANEEL (ANEEL – Res 300, 2008), para aplicação das medições é necessário (i) possuir uma linguagem comum entre compradores, vendedores e fornecedores dos PEEs da ANEEL; (ii) técnicas que permitam determinar as economias nos PEEs da ANEEL; (iii) contar com a capacidade logística para aplicar o programa de medições em qualquer comunidade de baixa renda; (iv) fornecer os procedimentos de medição; (v)

procedimentos e custos para diferentes níveis de exatidão; e (vi) elaborar um documento que inclui metodologia e procedimentos adotados nas medições.

Os aparelhos de medição utilizados para esta metodologia devem pelo menos ter as seguintes medições: (i) ponto medido; (ii) formatação ano/dia/hora/minuto; (iii) consumo de energia do equipamento; e (iv) potência do equipamento. Esses dados recomendam-se ter medições instantâneas em intervalos de 5 minutos, com uma confiabilidade de 95%, assim como a possibilidade da interface com Excel.

Em relação ao tempo de medição *ex-ante* e *ex-post*¹² dos PEEs, de acordo com o PIMVP a

“duração do período de determinação da economia deve ser determinada com a devida consideração pela duração da ação de EE e pela probabilidade de degradação da economia originalmente obtida ao longo de tempo” (EVO, 2012).

Nesse sentido, a ANEEL recomendou que os PEEs fossem elaborados em períodos curtos (semanas), para sua M&V.

3.1.2 Obtenção dos dados a partir de comunicação com a concessionária

Uma segunda forma para a obtenção dos dados é a partir de comunicação interna com uma distribuidora. Neste caso, os dados previamente cumprem todo o desenho de um PEE, aprovado pela ANEEL, e encontram-se prontos para a M&V. Na tese, os dados utilizados foram obtidos a partir de comunicação interna com o diretor do programa *International Initiative – Latin America* (IEI-LA)¹³ Prof. Dr. Gilberto de Martino Januzzi, organização responsável por apoiar a Light S.A., na M&V dos PEEs. Esses PEEs correspondem a programas desenvolvidos nas cidades de Rio de Janeiro e Volta Redonda, no Estado do Rio de Janeiro.

¹² *Ex-ante* refere-se ao período antes da medição e *ex-post* refere-se ao período depois da medição.

¹³ International Energy Initiative. Informações disponíveis no site <<http://iei-la.org/>>

3.1.3 Pesquisas de opinião

Para a obtenção dos dados foram apresentados anteriormente dois procedimentos baseados em dados de medições. No primeiro caso, a partir do desenho de um PEE e, no segundo caso, por meio da comunicação direta com a distribuidora. No entanto, a metodologia desenvolvida neste capítulo, permite a obtenção dos dados a partir de pesquisas de opinião. Neste caso, em comunidades de baixa renda próximas e de condições socioeconômicas iguais, em relação aos dados previamente medidos. As informações necessárias para aplicação do modelo são tempo de banho e quantidade de banho. Para tanto, sugere-se aplicar a seguinte entrevista de opinião no período *ex-ante* e no período *ex-post*.

Questionário Ex-ante

1. Identificação

a. Entrevistador _____ (Informação interna)

b. Data da entrevista _____

c. Entrevistado _____

d. Unidade Consumidora _____ (Informação interna)

2. Informações relacionadas com o CE

a. Você tem CE? Sim _____ Não _____

Se a resposta é não, a entrevista termina; caso contrário, continua.

b. Quantos chuveiros possui? _____

c. Aproximadamente quanto é a potência do seu CE?

_____ 3000 W

_____ 4400 W

_____ 4500 W

_____ 4800 W

_____ 5500 W

____ 6400 W

d. Qual é a tensão de operação do seu chuveiro ?

____ 127 V

____ 220 V

e. Quanto considera que é o tempo adequado para tomar banho (pergunta para cada morador)?

____ entre 3 e 5 minutos

____ entre 5 e 8 minutos

____ entre 8 e 10 minutos

____ mais que 10 minutos

3. Sobre o tempo e quantidade de banhos responda:

a. Quantas pessoas moram na sua residência?

____ 2

____ 3

____ 4

____ 5

____ 6

____ mais de 6

Cada morador deve responder as questões seguintes.

b. Toma banho geralmente em quais horários durante a semana (pode escolher vários)?

____ antes das 4h

____ entre 4h e 5h

____ entre 5h e 6h

____ entre 6h e 7h

____ entre 7h e 8h

____ entre 8h e 9h

____ entre 9h e 10h

____entre 10h e 11h

____entre 11h e 12h

____entre 12h e 13h

____entre 13h e 14h

____entre 14h e 15h

____entre 15h e 16h

____entre 16h e 17h

____entre 17h e 18h

____entre 18h e 19h

____entre 19h e 20h

____entre 20h e 21h

____entre 21h e 22h

____entre 22h e 23h

____depois das 23h

c. Toma banho geralmente em quais horários no fim de semana (pode escolher vários)

____antes das 4h

____entre 4h e 5h

____entre 5h e 6h

____entre 6h e 7h

____entre 7h e 8h

____entre 8h e 9h

____entre 9h e 10h

____entre 10h e 11h

____entre 11h e 12h

____entre 12h e 13h

____entre 13h e 14h

____entre 14h e 15h

____entre 15h e 16h

____entre 16h e 17h

____entre 17h e 18h

____entre 18h e 19h

____entre 19h e 20h

____entre 20h e 21h

____entre 21h e 22h

____entre 22h e 23h

____depois das 23h

d. Duração dos seus banhos

____ a duração do seu banho é menor que 2 minutos

____ a duração do seu banho está entre 2 e 3 minutos

____ a duração do seu banho está entre 3 e 4 minutos

____ a duração do seu banho está entre 4 e 5 minutos

____ a duração do seu banho está entre 5 e 6 minutos

____ a duração do seu banho está entre 6 e 7 minutos

____ a duração do seu banho está entre 7 e 8 minutos

____ a duração do seu banho está entre 8 e 9 minutos

____ a duração do seu banho está entre 9 e 10 minutos

____ a duração do seu banho é superior a 10 minutos

Término da entrevista

Data_____ Hora_____

Questionário Ex-post

1. Identificação

a. Entrevistador _____ (Informação interna)

b. Data da entrevista _____

c. Entrevistado _____

d. Unidade Consumidora _____ (Informação interna)

2. Informações relacionadas com o CE

a. Você tem CECET? _____ ou CERC? _____

b. Quantos chuveiros possui? _____

c. Quanto considera que é o tempo adequado para tomar banho (pergunta para cada morador)?

_____ entre 3 e 5 minutos

_____ entre 5 e 8 minutos

_____ entre 8 e 10 minutos

_____ mais que 10 minutos

3. Sobre o tempo e quantidade de banhos, responda:

a. Quantas pessoas moram na sua residência?

_____ 2

_____ 3

_____ 4

_____ 5

_____ 6

_____ mais de 6

Cada morador deve responder as perguntas seguintes.

b. Toma banho geralmente em quais horários durante a semana (pode escolher vários)?

_____ antes das 4h

_____ entre 4h e 5h

_____ entre 5h e 6h

_____ entre 6h e 7h

_____ entre 7h e 8h

- ____entre 8h e 9h
- ____entre 9h e 10h
- ____entre 10h e 11h
- ____entre 11h e 12h
- ____entre 12h e 13h
- ____entre 13h e 14h
- ____entre 14h e 15h
- ____entre 15h e 16h
- ____entre 16h e 17h
- ____entre 17h e 18h
- ____entre 18h e 19h
- ____entre 19h e 20h
- ____entre 20h e 21h
- ____entre 21h e 22h
- ____entre 22h e 23h
- ____depois das 23h

c. Toma banho geralmente em quais horários no fim de semana (pode escolher vários)?

- ____antes das 4h
- ____entre 4h e 5h
- ____entre 5h e 6h
- ____entre 6h e 7h
- ____entre 7h e 8h
- ____entre 8h e 9h
- ____entre 9h e 10h
- ____entre 10h e 11h
- ____entre 11h e 12h

____entre 12h e 13h

____entre 13h e 14h

____entre 14h e 15h

____entre 15h e 16h

____entre 16h e 17h

____entre 17h e 18h

____entre 18h e 19h

____entre 19h e 20h

____entre 20h e 21h

____entre 21h e 22h

____entre 22h e 23h

____depois das 23h

d. Duração dos seus banhos

____ a duração do seu banho é menor que 2 minutos

____ a duração do seu banho está entre 2 e 3 minutos

____ a duração do seu banho está entre 3 e 4 minutos

____ a duração do seu banho está entre 4 e 5 minutos

____ a duração do seu banho está entre 5 e 6 minutos

____ a duração do seu banho está entre 6 e 7 minutos

____ a duração do seu banho está entre 7 e 8 minutos

____ a duração do seu banho está entre 8 e 9 minutos

____ a duração do seu banho está entre 9 e 10 minutos

____ a duração do seu banho é superior a 10 minutos

Término da entrevista

Data_____ Hora_____

3.2 Chuveiros elétricos usados nos PEEAs nas amostras – Etapa 2

Em relação aos tipos de tecnologias usadas no aquecimento de água, no Brasil, as mais usadas são o chuveiro elétrico, o aquecedor elétrico de água, o aquecedor a gás, o aquecedor solar e a bomba de calor. Em 2011, das unidades produzidas, 95,07% corresponderam aos chuveiros elétricos, 3,01% aos aquecedores elétricos de água, 1,83% aos aquecedores solares, 0,04% aos aquecedores a gás, e 0,03% às bombas de calor. Esses resultados mostram claramente o domínio do chuveiro elétrico frente ao uso de outras tecnologias (CASTRO, 2014).

De acordo com as tecnologias disponíveis para substituição ou redução do consumo de energia elétrica nos chuveiros elétricos, nas amostras utilizadas neste trabalho, foram implementadas ações baseadas em dois tipos de tecnologias de chuveiros (a) chuveiro elétrico com controlador eletrônico de temperatura (CECET) e (b) chuveiro elétrico com recuperador de calor (CERC).

a) Controlador eletrônico de temperatura

No caso do controlador eletrônico de temperatura, uma vez acoplado ao chuveiro existente, o consumidor tem a possibilidade de regular a temperatura necessária para tomar um banho adequado. A vantagem é que o controle da temperatura do banho não precisa ser feito por meio do aumento ou redução da vazão de água, o que poderia acarretar maior gasto de água ou de energia elétrica para a mesma temperatura de banho. Por exemplo, no uso do chuveiro convencional, se a temperatura do banho está muito quente, o usuário geralmente aumenta a vazão de água para reduzir a temperatura. Com o CECET a potência é reduzida pelo usuário até chegar na temperatura desejada, para uma mesma vazão de água.

Outra vantagem em comparação com o chuveiro tradicional, é que esse equipamento, em tese, aumenta a vida útil da resistência elétrica do chuveiro, por fazer com que a resistência fique menos sujeita a correntes e temperaturas altas. A desvantagem é que o equipamento está sujeito ao comportamento humano. Então, é indispensável que o usuário tenha bons hábitos de uso, regulando a quantidade de água aquecida durante o uso. Na Figura 3.2, pode-se observar o CECET.



Figura 3.2 - Chuveiro elétrico com controlador eletrônico de temperatura nos PEEs da ANEEL.

Fonte: Controlador de temperatura para chuveiro (ECOSHOWER, 2015).

b) Recuperador de calor

O princípio de funcionamento do CERC é baseado em recuperar parte da energia térmica da água quente que sai do chuveiro, para pré-aquecer a água que ainda será aquecida pela resistência elétrica. Isso faz com que a água entre no chuveiro com uma temperatura mais elevada do que o normal e, assim, seja necessário menos energia para elevar sua temperatura até a temperatura de banho. Essa diferença permite ter resistências menores no chuveiro.

A Figura 3.3 ilustra seu funcionamento de modo simples. A água sai aquecida do chuveiro elétrico pela resistência elétrica. Antes de atingir o chão e entrar pelo ralo, passa em volta de uma serpentina metálica de alumínio, de espessura bastante fina, que fica abaixo do tapete de PVC sobre o qual o usuário se encontra. A água fria que vem da caixa da água, que antes iria diretamente para o chuveiro elétrico, passa antes pelo interior da serpentina, recebendo calor da água quente do banho que passa por fora do tubo da serpentina, aumentando sua temperatura (as duas águas não se misturam). Essa água pré-aquecida que passou dentro da serpentina, entra no chuveiro, onde será aquecida pela resistência térmica até a temperatura de banho (REVISTA FAPESP, 2007).




Figura 3.3 - Princípio de funcionamento do recuperador de calor nos PEEs da ANEEL.
 Fonte: Informações disponíveis no site Recuperador de calor (REVISTA FAPESP, 2007).

3.3 Modelagem usando inteligência artificial

Na Figura 3.4 é proposto o modelo para a previsão do consumo de energia elétrica antes e depois da troca dos CEs nos PEEs. Para tanto, foram consideradas duas entradas e uma saída. As entradas são o tempo de banho e a quantidade de banho por hora; e a saída é a previsão de carga por hora. As previsões são feitas para cada unidade consumidora e, posteriormente, é calculada a curva de carga diária média (*ex-ante* e *ex-post*) para cada uma das amostras na área de estudo.




Figura 3.4 - Modelo usado para a previsão do consumo de energia elétrica.

3.3.1 Modelagem *Fuzzy* – Etapa 3

A lógica *Fuzzy*, teoria desenvolvida por Zadeh (1965), baseia-se na compreensão dos quantificadores de qualidade usados na comunicação oral, por meio de valores matemáticos. Neste sentido, não existem fronteiras exatas e usam-se os conjuntos difusos na interpretação das expressões linguísticas. Os principais conceitos desenvolvidos na lógica *Fuzzy* foram as variáveis linguísticas, as funções de pertinência (“*membership*”) e as restrições *Fuzzy*. Posteriormente, Mamdani e Assilian (1975) criaram o primeiro controlador *Fuzzy*. Esse controlador tem a capacidade de fazer inferência, sendo, por isso, conhecido como o Sistema de Inferência *Fuzzy* (SIF). A principal vantagem do controlador *Fuzzy* é a habilidade na

solução de sistemas complexos. Caso tais sistemas fossem resolvidos por métodos tradicionais, suas soluções seriam muito mais complexas ou quase impossíveis.

a. Conjunto Fuzzy

A função $A(x): U \rightarrow \{0,1\}$ é conhecida como função característica na teoria clássica de conjuntos. Zadeh (1965) propôs uma caracterização mais abrangente, considerando que alguns membros têm mais participação em um conjunto que em outro. Nesse sentido, o fator de pertinência pode assumir diferentes valores entre 0 e 1.

De acordo com a Equação (2), um subconjunto A pode ser identificado pela seguinte função:

$x \rightarrow \{0,1\}$, chamado:

$$A(x) = \begin{cases} 1 & \text{se } x \in A \\ 0 & \text{se } x \notin A \end{cases} \quad (2)$$

Um conjunto *Fuzzy* $A: x \rightarrow [0,1]$, existe se um $x \in X$, assim como $A(x) = 1$.

Um conjunto *Fuzzy* $A: R \rightarrow [0,1]$ é convexo, se $x \leq y \leq z$; isso é verdade se $f(y) \geq f(x) \wedge f(z)$. Neste caso, o conjunto *Fuzzy* $A: R \rightarrow [0,1]$, tem um intervalo definido e é convexo (ZADEH, 1965).

b. Funções de pertinência

As funções de pertinência mais usadas em controle *Fuzzy*, incluem a Triangular, a Trapezoidal, a Gaussiana, a Sigmoide Z e as Funções S, dentre outras (NGUYEN *et al.* 2002). Para a metodologia aplicada neste trabalho, foi usada a Função Gaussiana. Entretanto, outras funções podem ser utilizadas. A seguir são apresentadas as funções mais usadas, por meio das equações (3), (4) e (5):

A Função Triangular, com pontos $(a, 0)$, $(b, 0)$ e (c, a) , é definida por:

$$A(x) = \begin{cases} \propto \left(\frac{x-a}{c-a} \right), & \text{se } a \leq x \leq c \\ \propto \left(\frac{x-a}{c-b} \right), & \text{se } c \leq x \leq b \\ 0, & \text{demais casos} \end{cases} \quad (3)$$

A Função Trapezoidal, com pontos $(a, 0)$, $(b, 0)$, (c, a) e (d, a) , é definida por:

$$A(x) = \begin{cases} \propto \left(\frac{x-a}{c-a} \right), & \text{se } a \leq x \leq c \\ \propto \left(\frac{x-b}{d-b} \right), & \text{se } c \leq x \leq d \\ 0, & \text{demais casos} \end{cases} \quad (4)$$

Na Função Gaussiana, o parâmetro c determina o centro da função e, o σ , a forma da curva. Os valores $c = 0$ e $\sigma = 1$, definem a Função de Pertinência Gaussiana padrão.

$$A(x) = e^{-\frac{(x-c)^2}{2\sigma^2}} \quad (5)$$

Essas funções, conhecidas como funções de pertinência, quantificam as condições linguísticas de um fenômeno. A título de exemplificação, a função triangular pode representar um dia que tem diferentes temperaturas, variando desde um dia muito frio, até um dia muito quente, passando pelo frio e quente, na medida em que o declive da função aumenta e depois diminui.

c. Combinando conjuntos Fuzzy

As operações básicas existentes na teoria clássica de conjuntos, também são aplicadas à lógica *Fuzzy*, da mesma forma como se apresentam nas equações (6), (7) e (8). Logo, seja X um conjunto *Fuzzy*, temos:

$$AND (\vee): \quad A \cap B = \{x \in X: x \in A \vee x \in B\} \quad (\text{Interseção}) \quad (6)$$

$$NOT: \quad X - A = \{x \in X: x \notin A\} \quad (\text{Complemento}) \quad (7)$$

$$OR (\wedge): \quad A \cup B = \{x \in X: x \in A \wedge x \in B\} \quad (\text{União}) \quad (8)$$

Abaixo, encontram-se as funções características para interseção (9), união (10) e complemento (11).

$$(A \cap B)(x) = \begin{cases} 1 & \text{se } x \in A \vee x \in B \\ 0 & \text{se } x \notin A \wedge x \notin B \end{cases} \quad (9)$$

$$(A \cup B)(x) = \begin{cases} 1 & \text{se } x \in A \wedge x \in B \\ 0 & \text{se } x \notin A \vee x \notin B \end{cases} \quad (10)$$

$$(X - A)(x) = \begin{cases} 1 & \text{se } x \notin A \\ 0 & \text{se } x \in A \end{cases} \quad (11)$$

d. Controlador Fuzzy Mamdani (Combinando regras Fuzzy)

O controlador *Fuzzy Mamdani* (MAMDANI; ASSILIAN, 1975), permite a modelagem matemática das funções de pertinência (entradas), a partir das regras *Fuzzy*. As regras *Fuzzy* são baseadas no conhecimento que o especialista tem sobre o fenômeno em questão. Desta forma, o especialista é quem desenha essas regras, que são geralmente expressas na forma “Se x é A , então y é B ”, onde A e B são conjuntos *Fuzzy*, sendo que x está no domínio de A e y está no domínio de B (NGUYEN *et al.* 2002).

Essas regras seguem as operações dos conjuntos – equações (12), (13), (14) e (15). De modo geral, para dois conjuntos A_i e B_i , as operações dos conjuntos *Fuzzy*, ocorrem da seguinte forma.

Se $A_i: x_i \rightarrow [0, 1]$, onde $i = 1$ e n é um conjunto *Fuzzy*, temos:

$$A: \prod_{i=1}^n X_i \rightarrow [0, 1] \text{ sendo } A(x_1, x_2, \dots, x_n) = A_1(x_1) \wedge \dots \wedge A_n(x_n) \quad (12)$$

Com as regras base

$$R_i: \text{Se } A_{i1} \text{ e } A_{i2} \text{ e } \dots \text{ e } A_{ik}, \text{ então } B_i, \quad i = 1, 2, \dots, n \quad (13)$$

Onde $A_{ij}: X_j \rightarrow [0,1]$ e $B_i: Y \rightarrow [0,1]$

Pode-se reduzir em:

$$R_i: \text{Se } A_i, \text{ então } B_i, \quad i = 1, 2, \dots, n \quad (14)$$

O que pode ser escrito como o conjunto

$$A_i = \prod_{j=1}^n A_{ij} : \prod_{j=1}^n X_j \rightarrow [0, 1] \quad (15)$$

A partir das regras “Se x é A_{ij} , então y é B_i ” $i=1,2,\dots,n$; onde $x = (x_1, x_2, \dots, x_k)$, a agregação das regras, usando a disjunção, é o que se conhece como o controlador Mamdani (MAMDANI; ASSILIAN, 1975).

As regras *Fuzzy* são aplicadas nas funções de pertinência, conforme as equações (16), (17), (18) e (19):

$$R(x, y) = \bigvee_{i=1}^n (A_i(x) \wedge B_i(y)) \quad (16)$$

Expandindo o conjunto de regras, obtém-se a equação (17):

$$R_i: \text{se } A_{i1} \wedge A_{i2} \wedge \dots \wedge A_{ik} \text{ então } B_i \quad i=1,\dots,n \quad (17)$$

$$R_x(y) = R(x_1, \dots, x_k, y) = \bigvee_{i=1}^n (A_{i1}(x_1) \wedge A_{i2}(x_2) \wedge \dots \wedge A_{ik}(x_k) \wedge B_i(y)) \quad (18)$$

A saída de controle para a regra R_i , com a entrada X_i é:

$$R_{i,x}(y) = A_i(x) \wedge B_i(y) \quad (19)$$

A agregação dessas regras produz um conjunto de saída *Fuzzy*.

e. Defuzzificação

Uma vez obtido o conjunto de saída *Fuzzy*, é preciso fazer um processo conhecido como *defuzzificação*, que consiste em obter um dado numérico na saída. São vários os métodos de *defuzzificação* que podem ser usados, incluindo (i) Método do Centro de Área, Centróide ou Centro de Gravidade; (ii) Método da Altura; (iii) Método da Média dos Máximos; e (iv) Método do Critério Máximo (LEE, 1990).

O método de *defuzzificação* que será apresentado neste trabalho corresponde ao método (i), que calcula o centro de área da região abaixo da curva definida por um conjunto de saída *Fuzzy*. Se C é integrável a função $C(z)$, então a saída numérica de $C(z)$ é z_0 , calculado conforme a equação (20):

$$z_0 = \frac{\int_a^b zC(z) dz}{\int_a^b C(z) dz}, \quad \text{onde } [a, b] \quad (20)$$

f. Sistema de Inferência Fuzzy (SIF)

Na Figura 3.5, apresenta-se o Sistema de Inferência *Fuzzy* (SIF). Este sistema permite a integração entre os conjuntos *Fuzzy* e as regras do conhecimento base, transformando esses resultados em valores numéricos, por meio da *defuzzificação*. Mais detalhadamente, na parte esquerda do fluxograma, observa-se o *fuzzificador*. Este faz a interface entre o conhecimento base e o módulo de tomada de decisão. Na parte central superior do fluxograma, tem-se o conhecimento base, que corresponde às regras feitas com base nas informações existentes, conhecidas pelo programador. Na parte inferior do fluxograma, tem-se a inferência, que corresponde ao módulo de tomada de decisões (nesse caso, o controlador lógico *Fuzzy*). Essa é a parte mais importante do modelo SIF, já que é a partir das regras e do conhecimento base, que o sistema faz a inferência para previsão da saída. Na parte direita do fluxograma, encontra-se o processo de *defuzzificação*, que consiste na obtenção de um resultado numérico, a partir da inferência feita pelo SIF.

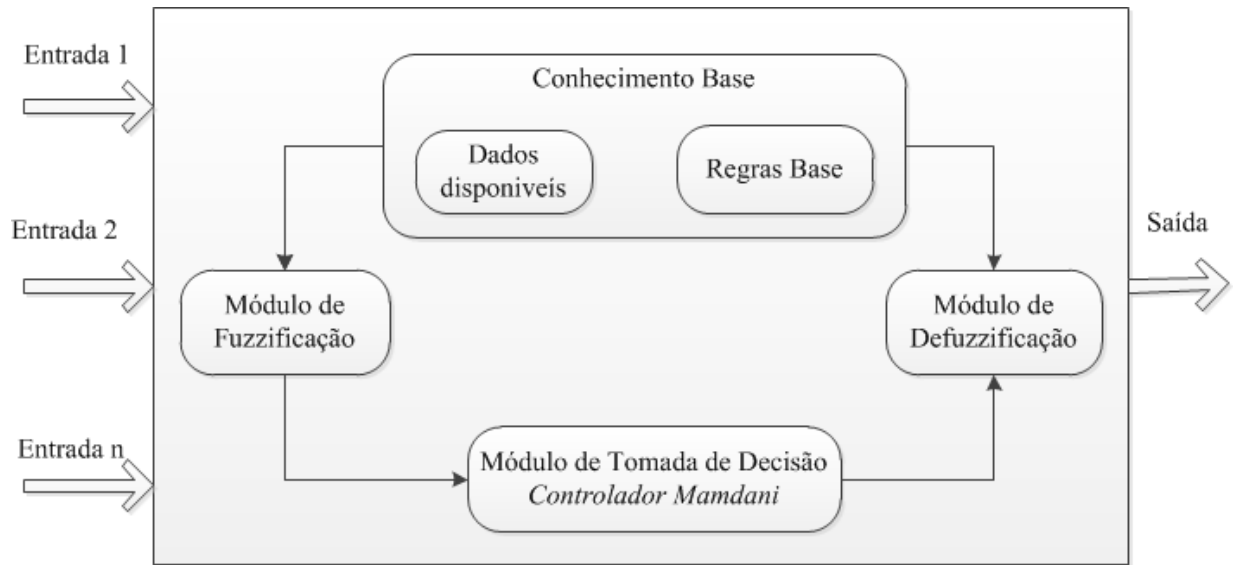


Figura 3.5 - Sistema de inferência *Fuzzy* para a previsão da curva de demanda.
 Fonte: Sistema de Inferência *Fuzzy*, adaptado de Jang (1993).

g. Modelagem SIF

A Figura 3.6 apresenta um fluxograma com os passos integrantes da Modelagem SIF, que incluem (i) leitura de dados; (ii) construção das funções de pertinência; e (iii) desenvolvimento do SIF (regras e inferência *Fuzzy*). Ao mesmo tempo, é construída a saída da curva de carga, com as medições atuais. Finalmente, compara-se o erro máximo e valida-se a saída do modelo, usando a abordagem *Fuzzy*.

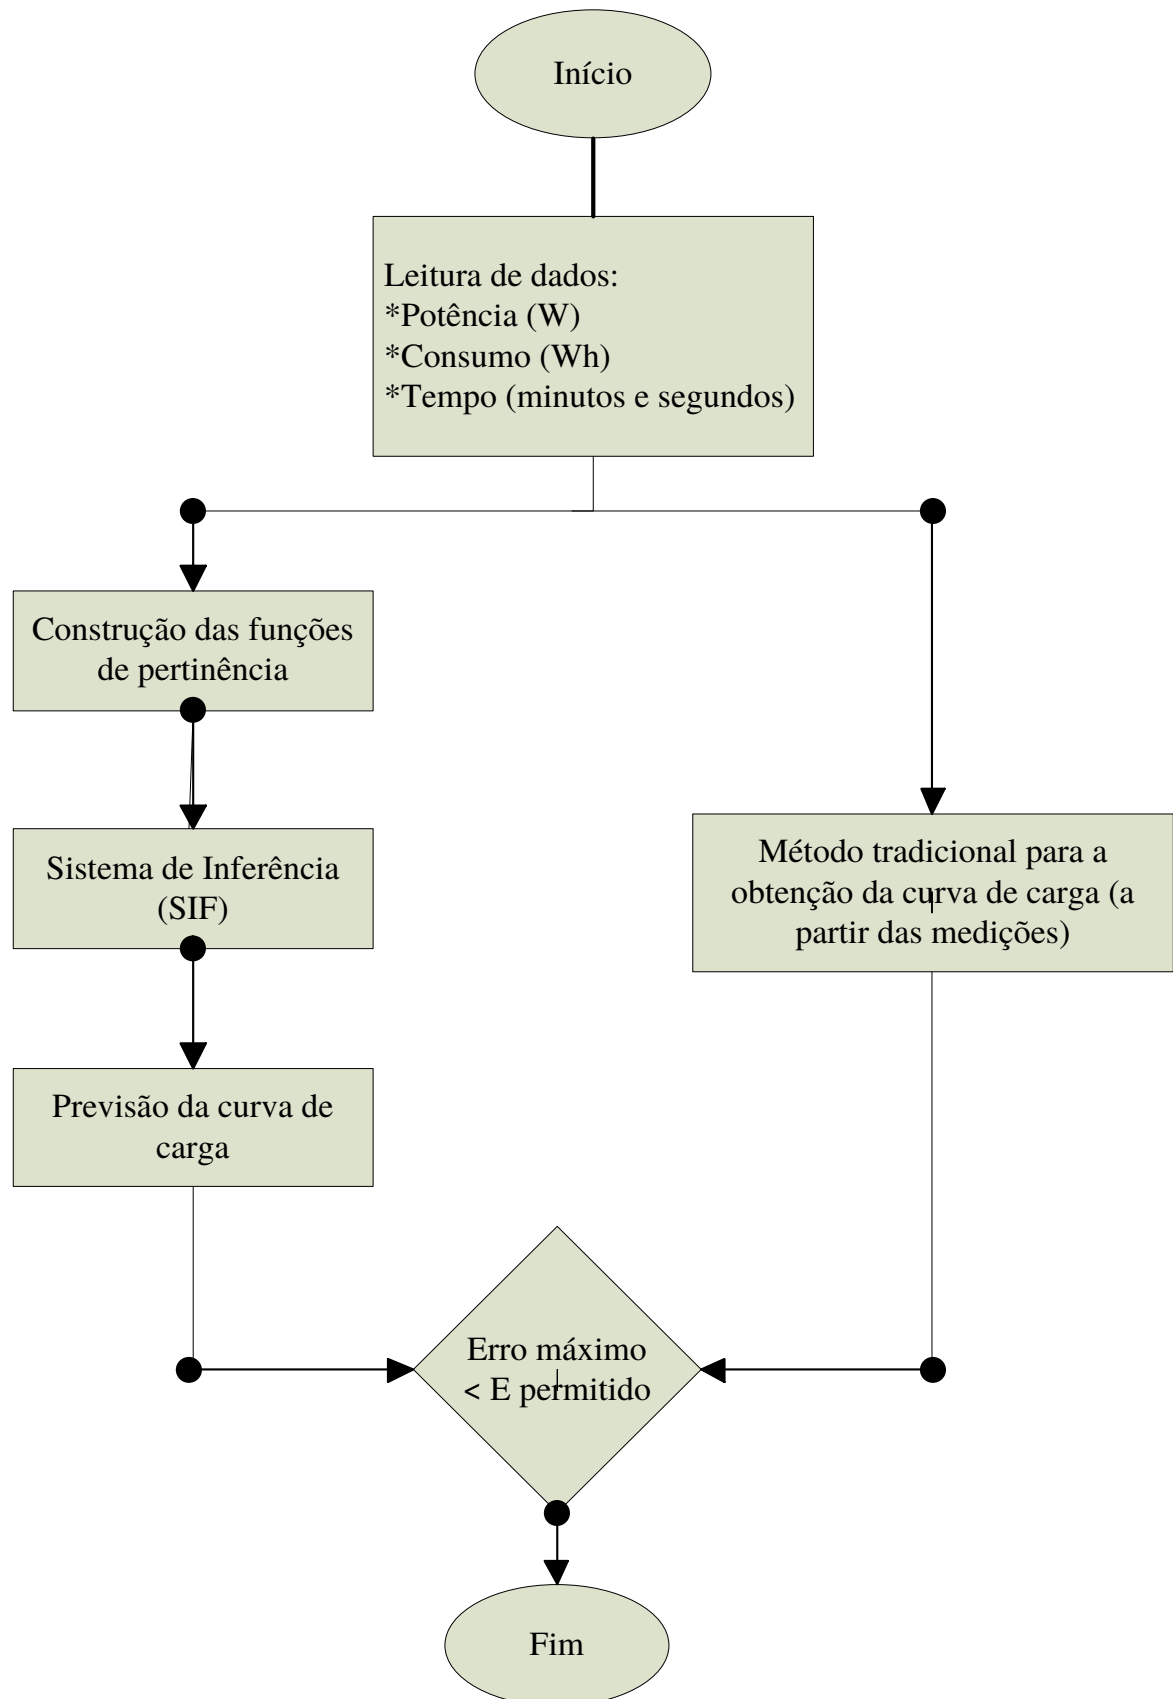


Figura 3.6 - Fluxograma para a previsão das curvas de carga usando a abordagem *Fuzzy*.

3.3.2 Modelagem usando Redes Neurais – Etapa 3

As RNAs foram desenvolvidas para emular o comportamento do cérebro humano, ou seja, ter a habilidade de aprender e de se adaptar quando são submetidas a estímulos (treinamento) (HAYKIN; NETWORK, 2004; LOPES; MINUSSI; LOTUFO, 2005). As RNAs são uma boa ferramenta para modelagem e previsão de sistemas complexos não lineares. Suas vantagens devem-se à capacidade de adaptação e à habilidade de treinamento que lhes permitem ser aplicadas em outros casos de estudo com condições semelhantes.

As RNAs são empregadas em muitas áreas de análise de sistemas elétricos de potência e em previsão da demanda de energia elétrica (TRIPATHI; UPADHYAY; SINGH, 2008). Uma vantagem das RNAs, em comparação à análise dos métodos clássicos das séries temporais, é que as RNAs permitem fazer previsões de curto prazo, de uma forma flexível e com maior precisão (KIARTZIS; BAKIRTZIS; PETRIDIS, 1995; TRIPATHI; UPADHYAY; SINGH, 2008; AL-FUHAID; EL-SAYED; MAHMOUD, 1997).

São diversas as arquiteturas das RNAs existentes e usadas para previsão. Dentre as mais conhecidas, estão a *Hopfield*, *Back Propagation* (BP), a máquina de *Boltzmann* e as redes *feedforward* (alimentada adiante) e *recurrent* (recorrente), que trabalham de acordo com o fluxo das saídas (PENG; HUBELE; KARADY, 1992). Uma das mais usadas é o algoritmo BP, para previsão de curto prazo (SÖZEN; ARCAKLIOĞLU; ÖZKAYMAK, 2005) (MAHMOUD *et al.* 2012).

a) O que é uma RNA

Os sistemas biológicos têm a capacidade de realizar tarefas complexas, em virtude da capacidade de aprender gradualmente a partir dos erros. Esse mesmo conceito foi aplicado no desenvolvimento das redes neurais, de forma que as RNAs são modelos matemáticos, desenvolvidos a partir da compreensão do sistema nervoso. O modelo matemático das redes neurais é baseado nos princípios descritos a seguir (NGUYEN *et al.* 2002).

1. Os neurônios são unidades elementares do sistema nervoso, onde ocorre o processamento da informação.
2. A informação recebida é transmitida a partir de sinais que são levados entre os

neurônios (camadas intermediárias).

3. Cada conexão tem um peso que multiplica o sinal transmitido.
4. Cada neurônio tem uma ação interna, conhecida como função de ativação aplicada; a soma ponderada das entradas dos sinais produz o sinal de saída.

b) Modelo de McCulloch e Pitts (Feedforward Neural Network)

O primeiro modelo de uma rede neural foi definido pela equação (21) (MCCULLOCH; PITTS, 1943):

$$f(x) = \begin{cases} 1, & \text{se } x \geq 0 \\ 0, & \text{se } x < 0 \end{cases} \quad (21)$$

A função de ativação desse neurônio é dada pela equação (22):

$$f\left(\sum_{i=1}^n w_i x_i - b\right) = \begin{cases} 1 & \text{se } \sum_{i=1}^n w_i x_i \geq b \\ 0 & \text{se } \sum_{i=1}^n w_i x_i < b \end{cases} \quad (22)$$

Na Figura 3.7, apresenta-se a saída das RNAs, caracterizada pelos seguintes parâmetros, $\theta = (w_1, \dots, w_n, b, f)$, onde w_i , corresponde ao peso, b é a função de ativação e y a saída da RNA.




Figura 3.7 - Rede neural de um neurônio com n entradas.

Fonte: Adaptado de Nguyen *et al.* (2002)

c) Aprendizagem de uma RNA

A aprendizagem de uma rede neural consiste na modificação dos pesos (w_i) e funções de ativação (b) de uma RNA. O objetivo da aprendizagem é treinar a RNA no desempenho de uma tarefa e obter resultados com erro aceitável. Os processos de aprendizagem de uma RNA são descritos a seguir (JANG; SUN; MIZUTANI, 1997).

- Aprendizagem supervisionada: nesse tipo de aprendizagem de RNA, um conjunto de resultados esperados é fornecido. O cálculo do erro permite que a matriz de pesos seja ajustada. Nesse caso, a RNA é aperfeiçoada a cada série de treinamentos.
- Aprendizagem não supervisionada: nesse caso, nenhuma saída antecipada ou resposta desejada é fornecida. Nessa RNA, apenas um único neurônio na camada de saída dispara uma resposta. Esse tipo de RNA é geralmente utilizado para a classificação dos padrões de entrada.
- Aprendizagem por reforço: essa abordagem é diferente das anteriores, pois nesse caso não existe uma interação direta com o modelo ou com a saída. Na aprendizagem por reforço, existe um objetivo a ser alcançado. Durante o processo de aprendizagem, a rede neural faz ações de saída e vai receber um sinal de reforço (estímulo) do ambiente, que permite avaliar a qualidade de sua ação.

d) A regra Delta

A regra Delta é um algoritmo de aprendizagem para uma rede neural de uma camada. Esse algoritmo é o precursor do algoritmo *Back-Propagation* (BP) para redes neurais multicamadas. A ideia do algoritmo é obter o ponto de mínimo por meio de um processo de iteração local, utilizando um exemplo do conjunto de treinamento por vez. Partindo-se de um ponto arbitrário w_o , pode-se ir pela superfície $E(w)$, em direção ao ponto mínimo. Para tanto, o ponto evolui no sentido oposto ao do gradiente naquele ponto. Nas equações (23) e (24), apresenta-se a formulação da regra Delta (WIDROW; HOFF, 1960).

$$w_i(k+1) = w_i(k) - \eta \cdot \text{grad}(E(w(k))) \quad (23)$$

$$w_i(k+1) = w_i(k) - \eta \frac{dE(w(k))}{dw_i} \quad (24)$$

e) O algoritmo Back-Propagation (BP)

O algoritmo BP é uma generalização da regra Delta. Como foi mencionado anteriormente, a regra Delta é uma RNA somente de uma camada e de um neurônio. Não obstante, o algoritmo BP contém vários neurônios e pode conter, também, várias camadas. Nesse processo, o algoritmo BP atualiza a matriz de pesos de acordo com a taxa de aprendizagem do algoritmo. A seguir são apresentadas as características mais importantes do algoritmo BP.

- Um padrão é apresentado à camada de entrada da rede. A atividade resultante flui através da rede, camada por camada, até que a resposta seja produzida pela camada de saída.
- A saída obtida é comparada à saída desejada para esse padrão particular. Se ela não estiver correta para esse padrão particular, o erro é propagado a partir da camada de entrada e os pesos das conexões das unidades das camadas internas vão sendo modificados conforme o erro é retropropagado.

Em comparação com a regra Delta, o BP trabalha com uma variação da regra Delta para redes multicamadas, que é conhecida como a regra Delta generalizada. No caso do algoritmo BO a taxa de aprendizado é uma constante de proporcionalidade no intervalo $[0,1]$.

O peso é atualizado em função da taxa de aprendizado e a entrada de acordo com a equação (25) (NGUYEN *et al.* 2002).

$$\Delta w_{ik}^q = -\eta \delta_i^q x_k^q \quad (15)$$

Onde:

w corresponde ao peso

η corresponde à taxa de aprendizado

x entrada da rede neural. $i = 1, \dots, n$ número de entradas

q = atualização.

A função δ é calculada por meio da equação (26).

$$\delta_i^q = (O_i^q - y_i^q) f' \left(\sum_{j=0}^n w_{ij} x_j^q \right) \quad (26)$$

f) Multicamada (Multilayer Perceptrons)

Uma rede neural multicamada (*Multilayer Perceptrons – MLP*), consiste em uma rede neural de várias camadas. Nessa arquitetura, a rede neural multicamada desempenha a mesma função nas entradas, e na saída que em uma rede neuronal básica. A vantagem principal é devido à soma dos pesos nas camadas intermediárias, melhorando o processo de cálculo desses pesos a partir do gradiente de erro dos diversos neurônios. Outro aspecto de destaque, é o fato que a função de ativação não é linear, o que permite maior robustez e aprendizado da rede neuronal.

g) Modelagem usando redes neurais (RNAs)

Na Figura 3.8 é apresentado o fluxograma detalhado para a obtenção da previsão das curvas de carga, baseado na abordagem da RNA. No diagrama, encontram-se o algoritmo com os seguintes passos (i) leitura dos dados; (ii) seleção da arquitetura da RNA; (iii) treinamento da RNA e comparação com as curvas de carga tradicionais, seguida da validação com o erro permitido, para obtenção da previsão da curva de carga.

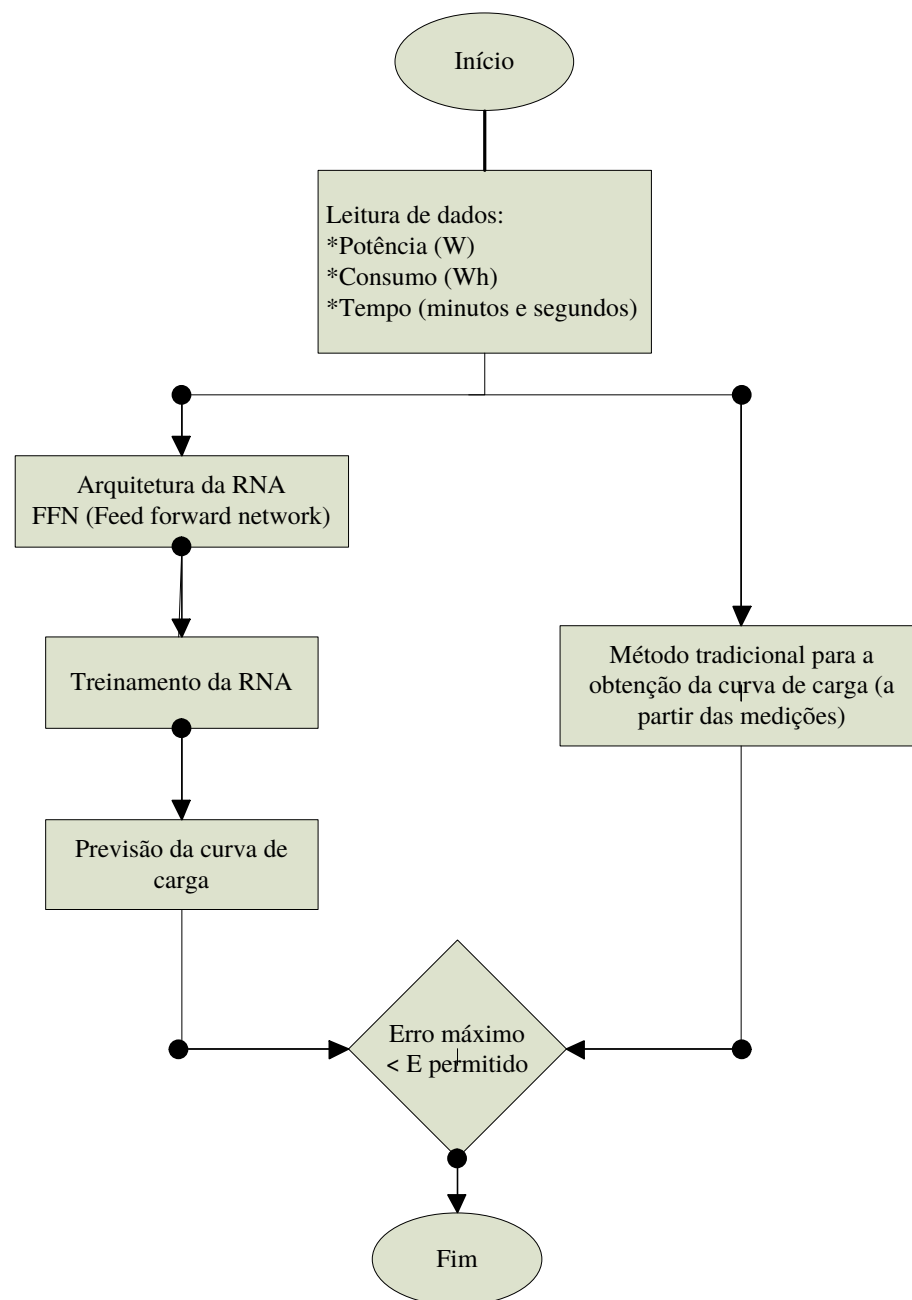


Figura 3.8. Diagrama de fluxo para a previsão das curvas de carga usando a abordagem da RNA.

3.3.3 Vantagens e desvantagens das abordagens *Fuzzy* e RNA.

Em seguida apresentam-se algumas vantagens e desvantagens das abordagens usadas neste trabalho, o que permite identificar a utilidade de cada método, seja baseado na lógica *Fuzzy* ou nas redes neurais. A lógica *Fuzzy* apresenta as vantagens descritas abaixo (KAR; DAS; GHOSH, 2014).

- A Lógica *Fuzzy* é baseada em palavras e não em números. Isso quer dizer que os valores-verdade são expressos linguisticamente.
- Melhor tratamento das imprecisões.
- Facilidade na especificação das regras de controle, em linguagem próxima à natural.
- O uso de variáveis linguísticas nos aproxima do pensamento humano.
- Simplifica a solução de problemas complexos e não lineares
- Simplifica a aquisição da base do conhecimento.
- Requer poucas regras, poucos valores e poucas decisões.

O SIF apresenta as desvantagens descritas abaixo.

- A influência da grande quantidade de parâmetros na configuração geralmente é feita pelo usuário, algumas das quais são o número de funções de pertinência de cada variável e o número de regras.
- A precisão do sistema *Fuzzy* é limitada pela experiência do especialista na configuração dos parâmetros, a qual é determinada pelo conhecimento do mesmo.

Já as RNAs, apresentam as vantagens descritas abaixo.

- Aquisição automática de conhecimentos empíricos, a partir de uma base histórica de dados referentes a um problema.
- Boa capacidade de representação de conhecimentos, por meio da criação de relações ponderadas (pesos), entre as entradas e a saída do sistema.
- Facilidade no desenvolvimento dos algoritmos do modelo e de treinamento do mesmo.
- Simplifica a solução de problemas complexos e não lineares.

As RNAs apresentam as desvantagens descritas abaixo.

- Manipulação de dados quantitativos, aproximados e mesmo incorretos, com uma degradação gradual das respostas e perda de informação na saída.
- Dificuldade de configuração das redes em relação à sua estrutura inicial e também no que se refere aos parâmetros dos algoritmos de aprendizado.
- Dificuldade de explicitar os conhecimentos adquiridos pela rede, por meio de uma linguagem compreensível para o ser humano.

Para esse trabalho, foram revisadas diferentes técnicas de modelagem desde as técnicas tradicionais baseadas em séries temporais, até a possibilidade de técnicas mais complexas, como a modelagem *Neuro-Fuzzy*. Entretanto, com base nos dados disponíveis, as técnicas que permitiram melhor modelagem foram a lógica *Fuzzy* e as redes neurais. A lógica *Fuzzy* tem a capacidade de tomar decisões com base em dados não lineares. Por exemplo, na previsão do consumo do chuveiro, em que existe incerteza em relação às decisões do usuário referentes ao consumo de energia elétrica. Já as RNAs, têm a capacidade de aprender a partir dos erros obtidos no treinamento da rede, permitindo a obtenção de previsões da curva de carga.

3.4 Validade e verificação dos resultados – Etapa 5

Erro Absoluto Médio (EAM) e Erro Médio Porcentual Absoluto (EMPA) são dois dos métodos mais usados para validação e verificação dos erros em previsões (LOCE; DOUGHERTY, 1995). Neste trabalho, são usados para testar a validade dos resultados da previsão das modelagens *Fuzzy* e RNAs. A matemática usada para testar o erro, é dada pelas equações (27) e (28), onde y_m corresponde à potência medida e y_{ip} corresponde à potência prevista.

O erro absoluto é a diferença entre o valor previsto e o valor real. O EAM informa quão grande é o erro médio que podemos esperar, a partir da previsão (AKDEMIR; ÇETINKAYA, 2012).

$$EAM = \frac{1}{n} \sum_{i=1}^n |y_{im} - y_{ip}| \quad (27)$$

O EMPA também é baseado no erro médio, mas permite comparar as previsões em diferentes escalas, usando termos percentuais (AKDEMIR; ÇETINKAYA, 2012).

$$EMPA = \frac{100 * 1}{n} \sum_{i=1}^n \frac{|y_{im} - y_{ip}|}{y_{im}} \quad (28)$$

4 APLICAÇÃO DA METODOLOGIA PARA A PREVISÃO DE CURVAS DE CARGA NOS CHUVEIROS ELÉTRICOS, USANDO SIF E RNA

Este capítulo descreve a aplicação da metodologia, em etapas, para o desenvolvimento deste trabalho. Conforme já comentado previamente neste trabalho, a aplicação da metodologia consistiu em cinco etapas. Nas etapas 1 e 2 foram realizadas a escolha da amostra, e a descrição e o tratamento dos dados. Nas etapas 3 e 4 foram aplicadas, simultaneamente, as abordagens *Fuzzy* e RNA. Na etapa 5 são apresentados os resultados da aplicação das simulações no modelo, tanto para o CECET, como para o CERC. Os erros dos modelos foram validados usando o EAM e o EMPA. Por último, foi feita uma análise quantitativa dos PEEs das amostras estudadas.

4.1 Amostras e tratamento de dados – etapas 1 e 2

4.1.1 Amostras

A etapa 1 consistiu na obtenção dos dados ou na seleção das amostras. Neste caso, os dados foram fornecidos por comunicação interna com o Prof. Dr. Gilberto Jannuzzi, diretor do IEI¹⁴. Conforme apresentado na Figura 4.1, os PEEs foram realizados em duas cidades do Estado do Rio de Janeiro. Especificamente, esses PEEs foram aplicados na cidade de Volta Redonda e do Rio de Janeiro. Os objetivos desses PEEs foram (i) promover a eficiência energética nos aparelhos de uso final e (ii) reduzir a demanda na ponta.

¹⁴ International Energy Initiative. Informações disponíveis no site <<http://iei-la.org/>>. Para obter os dados das medições usados na tese entrar em contato com o Prof. Dr. Gilberto Jannuzzi.



Figura 4.1 - Cidades de aplicação da metodologia no Estado do Rio de Janeiro.

Fonte: Imagem livre e disponível no Google imagens.

4.1.2 Tamanho da amostra

De acordo com o Manual ProPEE (ProPEE - ANEEL, 2008), apresenta-se a quantidade de unidades consumidoras que devem fazer parte dos programas de M&V, para que as medições sejam representativas e significativas. As amostragens 1 e 2 foram obtidas em duas comunidades de baixa renda, localizadas na cidade de Volta Redonda, com 200 a 220 residências cada uma. De acordo com o ProPEE, para comunidades de baixa renda com 151 a 280 unidades consumidoras, 13 amostras (medições) são representativas e significativas. Nas amostragens 1 e 2, foram feitas 37 e 23 medições, respectivamente. Já a amostragem 3, foi obtida em comunidade de baixa renda na cidade do Rio de Janeiro, com aproximadamente 2200 residências. De acordo com o Manual ProPEE (ProPEE - ANEEL, 2008) são necessárias 50 amostras (medições), porém foram obtidas apenas 15 medições. Essa quantidade de medições não é representativa nem significativa para a amostragem 3.

Na Tabela 4.1 apresenta-se descrição detalhada das amostras. Essa tabela apresenta, a cidade onde foi feita a amostra (primeira coluna); o tipo de chuveiro usado no PEE (segunda coluna); a quantidade de residências amostradas (terceira coluna); as datas antes e depois do PEE (quarta e quinta colunas, respectivamente); e, finalmente, quais os dados coletados (sexta coluna).

Tabela 4.1 - Descrição de cada amostra dos PEEs da ANEEL para CE em Volta Redonda e no Rio de Janeiro.

Amostragem	Tipo de chuveiro	Quantidade de residências (n)	Data das medições <i>ex-ante</i> ¹⁵	Data das medições <i>ex-post</i> ¹⁶	Dados medidos
Amostragem 1 (controle) Volta Redonda (Bairro 1)	CECET	37	Entre 6 e 12 de setembro de 2013	Entre 18 e 24 de setembro de 2013	Potência (W) e consumo (Wh)
Amostragem 2 Volta Redonda (Bairro 2)	CERC	23	Entre 9 e 15 de setembro de 2013	Entre 18 e 24 de setembro de 2013	Potência (W) e consumo (Wh)
Amostragem 3. Rio de Janeiro (Bairro 1)	CERC	15	Entre 3 e 6 de junho de 2013	Entre 17 e 23 de junho de 2013	Potência (W) e consumo (Wh)

CERC: chuveiro elétrico com recuperador de calor.

CECET: chuveiro elétrico com controlador eletrônico de temperatura.

4.1.3 Tratamento dos dados

Os dados das três amostragens foram coletados com equipamentos de medição conhecidos como *data loggers*. Esse medidor (Figura 4.2) é constituído de uma caixa plástica

¹⁵ Ex-ante: corresponde às medições antes da troca do chuveiro.

¹⁶ Ex-post: corresponde às medições depois da troca do CE por CERC ou CECET.

que contém uma placa eletrônica, uma tomada macho, uma tomada fêmea, um conector H, um barramento lateral, um conector USB para a aquisição de dados e LEDs indicativos. O medidor permite a captura do consumo de energia (kWh), e da potência máxima atingida, obtidos a cada cinco minutos. O software do equipamento permite inserir o número da unidade consumidora e a data no formato (dia/mês/ano). Toda a leitura de dados é feita no software EXCEL (EXCEL, 2017).




Figura 4.2 - Medidor *data logger* usado nas medições das amostras.

Fonte: Medidor Power Save (POWERSAVE, 2017)

A modelagem para a previsão da carga nos CEs conta com duas entradas – tempo de banho e quantidade de banhos – e uma saída – previsão de carga, de acordo com a Figura 3.4, apresentada no Capítulo 3. Não obstante, uma das limitações do trabalho é a determinação real do tempo de banho. Nesse sentido, foram feitos dois procedimentos de tratamento dos dados (a) aproximação em tempo e quantidade de banhos e (b) considerando união de tempo e quantidade de banhos. Para calcular o tempo de banho, usou-se a equação (29), a qual se

baseia no consumo e na potência, obtidos durante a medição. Em relação à quantidade de banhos foi usado um contador do número de banhos.

$$\text{Tempo de banho} = \left(\frac{\text{Consumo}}{\text{Potência}} \right) \quad (29)$$

a) Aproximação em tempo de banho e quantidade de banhos

Nesta aproximação, usou-se o tempo de banho como evento independente, tanto em tempo, como em quantidade. Para isso, calculou-se a quantidade de banhos como o número de eventos ocorridos em uma hora (a ocorrência de consumo de energia foi considerada como banho).

Nesta aproximação, se um tempo de banho fosse superior a 4,9 min, poderia sugerir que outro banho fez parte desse evento. Tal consideração não foi feita nesta aproximação, já que a quantidade de banhos foi considerada como eventos independentes, o que permitiu a aplicação da metodologia de uma forma prática e simples.

Como exemplo, é apresentado detalhadamente, de maneira gráfica, o tratamento dos dados, considerando aproximação em tempo de banho e quantidade de banhos (Figura 4.3). A figura, apresenta a medição feita em um chuveiro de uma determinada residência, durante duas horas. Nessa figura, por exemplo, vê-se que as medições foram feitas em intervalos de 5 minutos. Dessa forma, tem-se um total de 12 medições por coluna, o que corresponde a uma hora. Na figura, observam-se os dados referentes à data da medição (primeira coluna); hora da medição (segunda coluna); e à energia consumida em kWh e potência máxima em W (na terceira e quarta colunas, respectivamente). A partir dos dados de potência e energia, foi calculado o tempo de banho (minutos) para cada intervalo, como explicado na equação (29).

	A	B	C	D	E	
1	Data	Hora	Consumo	Potência	Tempo	
2	06/09/2013	17:55:00	0.000000	0.000	0	
3	06/09/2013	18:00:00	0.000000	0.000	0	
4	06/09/2013	18:05:00	0.000000	0.000	0	
5	06/09/2013	18:10:00	0.000000	0.000	0	
6	06/09/2013	18:15:00	0.000000	0.000	0	
7	06/09/2013	18:20:00	0.000000	0.000	0	
8	06/09/2013	18:25:00	0.000000	0.000	0	
9	06/09/2013	18:30:00	0.000000	0.000	0	
10	06/09/2013	18:35:00	0.000000	0.000	0	
11	06/09/2013	18:40:00	0.279299	4699.590	3.5658302	Tempo de banho: 10,872475 min
12	06/09/2013	18:45:00	0.387073	4798.750	4.8396728	Quantidade de banhos: 3
13	06/09/2013	18:50:00	0.197088	4793.440	2.4669715	
14	06/09/2013	18:55:00	0.000000	0.000	0	
15	06/09/2013	19:00:00	0.000000	0.000	0	
16	06/09/2013	19:05:00	0.020582	4397.200	0.2808424	
17	06/09/2013	19:10:00	0.355482	4631.130	4.6055542	
18	06/09/2013	19:15:00	0.000000	0.000	0	
19	06/09/2013	19:20:00	0.000000	0.000	0	
20	06/09/2013	19:25:00	0.000000	0.000	0	
21	06/09/2013	19:30:00	0.000000	0.000	0	
22	06/09/2013	19:35:00	0.000000	0.000	0	
23	06/09/2013	19:40:00	0.000000	0.000	0	Tempo de banho: 9,8863965 min
24	06/09/2013	19:45:00	0.000000	0.000	0	Quantidade de banhos: 2
25	06/09/2013	19:50:00	0.000000	0.000	0	
26	06/09/2013	19:55:00	0.000000	0.000	0	

Figura 4.3 - Dados das medições considerando aproximação em tempo de banho e quantidade de banhos (EXCEL, 2017).

b) Considerando união de tempo e quantidade de banhos

Para a condição onde o tempo de banho fosse superior a 4,9 minutos, juntaram-se os eventos, considerando-os um único evento. Essa consideração foi chamada de união de tempo e quantidade de banhos. Por exemplo, na Figura 4.4, em uma determinada residência, entre 16h45min e 16h55min, apresentou-se um tempo de banho superior a 4,9 min. O tempo de banho de 16h50min foi somado ao tempo seguinte, como se observa nas colunas da direita, sendo esse novo tempo, um evento independente. Outro exemplo pode ser observado nas linhas inferiores, entre 17h20min e 17h35 min. Assim, o tempo de banho de 17h25min, foi somado ao evento seguinte, como no primeiro exemplo.

Data Logger	Data	Hora e Minutos	Consumo (kWh)	Potência (W)	Tempo (Minutos)	Quantidade		Data Logger	Data	Hora e Minutos	Consumo (kWh)	Potência (W)	Tempo (Minutos)	Quantidade
LOG	06/09/2013	16:00:00	0.0000	0.0000	0.0000	0		LOG	06/09/2013	16:00:00	0.0000	0.0000	0.0000	0
LOG	06/09/2013	16:05:00	0.0000	0.0000	0.0000	0		LOG	06/09/2013	16:05:00	0.0000	0.0000	0.0000	0
LOG	06/09/2013	16:10:00	0.0000	0.0000	0.0000	0		LOG	06/09/2013	16:10:00	0.0000	0.0000	0.0000	0
LOG	06/09/2013	16:15:00	0.0000	0.0000	0.0000	0		LOG	06/09/2013	16:15:00	0.0000	0.0000	0.0000	0
LOG	06/09/2013	16:20:00	0.0000	0.0000	0.0000	0		LOG	06/09/2013	16:20:00	0.0000	0.0000	0.0000	0
LOG	06/09/2013	16:25:00	0.0000	0.0000	0.0000	0		LOG	06/09/2013	16:25:00	0.0000	0.0000	0.0000	0
LOG	06/09/2013	16:30:00	0.0000	0.0000	0.0000	0		LOG	06/09/2013	16:30:00	0.0000	0.0000	0.0000	0
LOG	06/09/2013	16:35:00	0.0000	0.0000	0.0000	0		LOG	06/09/2013	16:35:00	0.0000	0.0000	0.0000	0
LOG	06/09/2013	16:40:00	0.0000	0.0000	0.0000	0		LOG	06/09/2013	16:40:00	0.0000	0.0000	0.0000	0
LOG	06/09/2013	16:45:00	0.1562	2830.0400	3.3117	1		LOG	06/09/2013	16:45:00	0.1562	2830.0400	3.3117	1
LOG	06/09/2013	16:50:00	0.2381	2913.7200	4.9038	1	→	LOG	06/09/2013	16:50:00	0.0000	0.0000	0.0000	0
LOG	06/09/2013	16:55:00	0.2330	2693.8500	4.8308	1		LOG	06/09/2013	16:55:00	0.4711	5807.5700	9.7346	1
LOG	06/09/2013	17:00:00	0.0000	0.0000	0.0000	0		LOG	06/09/2013	17:00:00	0.0000	0.0000	0.0000	0
LOG	06/09/2013	17:05:00	0.0000	0.0000	0.0000	0		LOG	06/09/2013	17:05:00	0.0000	0.0000	0.0000	0
LOG	06/09/2013	17:10:00	0.0000	0.0000	0.0000	0		LOG	06/09/2013	17:10:00	0.0000	0.0000	0.0000	0
LOG	06/09/2013	17:15:00	0.0000	0.0000	0.0000	0		LOG	06/09/2013	17:15:00	0.0000	0.0000	0.0000	0
LOG	06/09/2013	17:20:00	0.0585	2808.6000	1.2505	1		LOG	06/09/2013	17:20:00	0.0585	2808.6000	1.2505	1
LOG	06/09/2013	17:25:00	0.2368	3005.6800	4.9305	1	→	LOG	06/09/2013	17:25:00	0.0000	0.0000	0.0000	0
LOG	06/09/2013	17:30:00	0.2251	2865.5700	4.7135	1		LOG	06/09/2013	17:30:00	0.4620	5871.2500	9.6440	1
LOG	06/09/2013	17:35:00	0.0914	2794.9900	1.9622	1		LOG	06/09/2013	17:35:00	0.0914	2794.9900	1.9622	1
LOG	06/09/2013	17:40:00	0.0000	0.0000	0.0000	0		LOG	06/09/2013	17:40:00	0.0000	0.0000	0.0000	0
LOG	06/09/2013	17:45:00	0.0000	0.0000	0.0000	0		LOG	06/09/2013	17:45:00	0.0000	0.0000	0.0000	0
LOG	06/09/2013	17:50:00	0.0000	0.0000	0.0000	0		LOG	06/09/2013	17:50:00	0.0000	0.0000	0.0000	0
LOG	06/09/2013	17:55:00	0.0000	0.0000	0.0000	0		LOG	06/09/2013	17:55:00	0.0000	0.0000	0.0000	0
LOG	06/09/2013	18:00:00	0.0000	0.0000	0.0000	0		LOG	06/09/2013	18:00:00	0.0000	0.0000	0.0000	0

Figura 4.4 - Aproximação considerando união de tempo de banho e quantidade de banhos (EXCEL, 2017).

Cada unidade consumidora foi medida *ex-ante* e *ex-post*, no período de uma semana correspondendo a uma matriz (2016x4; dados) onde as colunas são: consumo (kWh), potência (W), tempo (minutos) e quantidade de banhos. Posteriormente, os dados foram organizados por horas pelos seguintes motivos (i) a análise por hora simplificou o número de dados; (ii) na maioria dos trabalhos científicos de previsão apresentados na revisão da literatura (Capítulos 2 e 3), as previsões foram feitas por horas; e (iii) essa estrutura dos dados por hora, permite a coleta de informação de forma mais simples e fácil. Em resumo, os dados ingressados no modelo correspondem a dois vetores, tempo de banho e quantidade de banho. Para cada unidade consumidora por dia, há 168 dados. Posteriormente, foi calculada a média das previsões nas residências, que foi comparada com o valor medido.

4.2 Aplicações das abordagens *Fuzzy* e a RNA – Etapas 3 e 4

Nas etapas 3 e 4, foram aplicadas duas abordagens de previsão neste trabalho, a lógica *Fuzzy* e as RNAs. A seguir é apresentada a aplicação da metodologia das duas abordagens.

4.2.1 Modelagem do SIF

Primeiramente, será explicado como foram obtidas as funções de pertinência. A título de exemplificação, será explicada a obtenção da função de pertinência para a saída da previsão de carga. Inicialmente, os dados foram ordenados de forma crescente, em função da potência, para divisão da previsão de carga em várias faixas, conforme a divisão que se segue (1) entre 270 e 400 W; (2) entre 500 e 900 W; (3) entre 850 e 1200 W; (4) entre 1100 e 1600 W; (5) entre 1350 e 2000 W; (6) entre 3000 e 3700 W; (7) entre 1750 e 2500 W ; e (8) entre 2400 e 3300 W. Identificou-se que a faixa entre 500 W e 1000 W, apresentava uma função de distribuição gaussiana (Figura 4.5), com média de 670 W e desvio padrão de 120 W. As modelagens para cada uma das funções de pertinência restantes, foram obtidas da mesma forma.




Figura 4.5 - Distribuição gaussiana para a faixa entre 500 W e 1000 W.

a) Funções de pertinência: aproximação em tempo e quantidade de banhos

Para a aplicação do método *Fuzzy*, foi desenvolvido um modelo de inferência nebulosa do tipo Mamdani (MAMDANI; ASSILIAN, 1975), usando o *Toolbox Fuzzy* do Matlab (MATHWORKS; WANG, 1998). A seguir, apresentam-se as funções de pertinência para as entradas e a saída. A primeira entrada corresponde à quantidade de banhos, que foi modelada como uma entrada discreta. Para tanto, foram consideradas distribuições gaussianas com um desvio reduzido. No total, são nove funções de pertinência. A função de pertinência da quantidade de banhos é apresentada graficamente na Figura 4.6 e, na Tabela 4.2, são apresentados os parâmetros para caracterização das funções de pertinência.




Figura 4.6 -Funções de pertinência da quantidade de banhos.

Tabela 4.2 - Funções de pertinência para a quantidade de banhos (aproximação).

Nome	Descrição da variável	Quantidade de banhos
Nd	Sem banhos	0 banhos
MMB	Quantidade de banhos muito, muito baixa	1 banho
MB	Quantidade de banhos muito baixa	2 banhos
B	Quantidade de banhos baixa	3 banhos
N	Quantidade de banhos normal	4 banhos
A	Quantidade de banhos alta	5 banhos
MA	Quantidade de banhos muito alta	6 banhos
MMA	Quantidade de banhos muito, muito alta	7 banhos
S	Quantidade de banhos superior	Acima de 8 banhos

A segunda entrada, tempo de banho, foi modelada usando 8 funções gaussianas. As funções de pertinência do tempo de banho são apresentadas na Figura 4.7 e os parâmetros das funções de pertinência são apresentados na Tabela 4.3.




Figura 4.7 - Funções de pertinência do tempo de banho.

Tabela 4.3 - Funções de pertinência para o tempo de banho (aproximação).

Nome	Descrição da variável	Dados estatísticos
MMB	Tempo de banho muito, muito baixo	$\mu = 1,80 \text{ min}; \sigma = 1,17 \text{ min}$
MB	Tempo de banho muito baixo	$\mu = 4,31 \text{ min}; \sigma = 1,89 \text{ min}$
B	Tempo de banho baixo	$\mu = 7,74 \text{ min}; \sigma = 2,46 \text{ min}$
N	Tempo de banho normal	$\mu = 10,31 \text{ min}; \sigma = 3,28 \text{ min}$
A	Tempo de banho alto	$\mu = 13,58 \text{ min}; \sigma = 3,96 \text{ min}$
MA	Tempo de banho muito alto	$\mu = 18,13 \text{ min}; \sigma = 5,12 \text{ min}$
MMA	Tempo de banho muito, muito alto	$\mu = 19,20 \text{ min}; \sigma = 6,20 \text{ min}$
S	Tempo de banho superior	$\mu = 25,34 \text{ min}; \sigma = 10,34 \text{ min}$

No que diz respeito à saída do modelo SIF, correspondente à previsão de carga, têm-se 9 funções gaussianas, de acordo com a Figura 4.8. Na Tabela 4.4, é apresentada a caracterização dessa função de pertinência.




Figura 4.8 - Função de pertinência da carga estimada.

Tabela 4.4 - Funções de pertinência para a saída de previsão de carga (aproximação).

Nome	Descrição da variável	Dados estatísticos (Potência no intervalo de uma hora)
Nd	Consumo zero	$M = 0; \sigma = 0$
CMMB	Consumo muito, muito baixo	$\mu = 336,59 \text{ W}; \sigma = 58,54 \text{ W}$
CMB	Consumo muito baixo	$\mu = 672,80 \text{ W}; \sigma = 120,70 \text{ W}$
CB	Consumo baixo	$\mu = 1020,20 \text{ W}; \sigma = 172,00 \text{ W}$
CN	Consumo normal	$\mu = 1344,10 \text{ W}; \sigma = 246,10 \text{ W}$
CA	Consumo alto	$\mu = 1682,00 \text{ W}; \sigma = 316,00 \text{ W}$
CMA	Consumo muito alto	$\mu = 2111,00 \text{ W}; \sigma = 369,00 \text{ W}$
CMMA	Consumo muito, muito alto	$\mu = 2423,90 \text{ W}; \sigma = 314,00 \text{ W}$
CS	Consumo superior	$\mu = 2822,00 \text{ W}; \sigma = 432,00 \text{ W}$

b) Sistema de Inferência Fuzzy (SIF)

Com a construção das funções de pertinência para as duas entradas e para a saída, associadas as regras desenvolvidas e ao controlador Mamdani (MAMDANI; ASSILIAN, 1975), foi desenvolvido o SIF, usado neste trabalho, para a previsão das curvas de carga. A seguir, apresenta-se como foram construídas as regras do SIF. Para potências entre 1000 W e 500 W, a duração do banho vai ser inferior a 14 min, com uma quantidade entre 1 e 3 banhos. Para potências abaixo de 500 W, tem-se durações de banho abaixo de 10 min, e uma quantidade entre 1 e 2 banhos. Para potências superiores a 3000 W, os banhos encontram-se no intervalo entre 18 e 20 minutos. Dessa forma, foram estabelecidas as relações entre todas as funções de pertinência, a fim de desenvolver as regras do SIF como apresentado na Tabela 4.5.

Tabela 4.5 - Regras do SIF.

Quantidade de banhos	Tempo de banhos (min)	Previsão de carga (W)
<i>Para quantidade de banho Nd (Exemplos)</i>		
Se quantidade de banhos é Nd e o tempo de banho é MMB		Então a saída da potência é Nd
Se quantidade de banhos é Nd e o tempo de banho é A		Então a saída da potência é Nd
Se quantidade de banhos é Nd e o tempo de banho é S		Então a saída da potência é Nd
<i>Para quantidade de banho MB (Exemplos)</i>		
Se quantidade de banhos é MB e o tempo de banho é MMB		Então a saída da potência é CMB
Se quantidade de banhos é MB e o tempo de banho é N		Então a saída da potência é CMB
Se quantidade de banhos é MB e o tempo de banho é S		Então a saída da potência é CB
<i>Para quantidade de banho N (Exemplos)</i>		
Se quantidade de banhos é N e o tempo de banho é MB		Então a saída da potência é CB
Se quantidade de banhos é N e o tempo de banho é N		Então a saída da potência é CN
Se quantidade de banhos é N e o tempo de banho é MMA		Então a saída da potência é CN
<i>Para quantidade de banho A (Exemplos)</i>		
Se quantidade de banhos é A e o tempo de banho é B		Então a saída da potência é CN
Se quantidade de banhos é A e o tempo de banho é MA		Então a saída da potência é CMA
Se quantidade de banhos é A e o tempo de banho é S		Então a saída da potência é CMA
<i>Para quantidade de banho S (Exemplos)</i>		
Se quantidade de banhos é S e o tempo de banho é MMB		Então a saída da potência é CMMB
Se quantidade de banhos é S e o tempo de banho é A		Então a saída da potência é CMA
Se quantidade de banhos é S e o tempo de banho é S		Então a saída da potência é CS

c) Defuzzificação

A partir das funções de pertinência (feitas com base nos dados das medições) e do conjunto de regras desenvolvido, que juntos correspondem ao conhecimento base, é produzida a saída da previsão. Esse resultado, por enquanto, é uma região de um conjunto que precisa ser transformado em um valor numérico. Esse valor numérico é obtido através da *defuzzificação* e corresponde à previsão de carga. Na Figura 4.9 é apresentado o processo de *defuzzificação* na abordagem *Fuzzy*. Nas primeiras duas colunas têm-se as entradas e, na terceira coluna, tem-se a saída do modelo. O modelo da figura corresponde ao controlador Mamdani, explicado amplamente no Capítulo 3, obtido por meio do *Toolbox Fuzzy* do Matlab (MATHWORKS; WANG, 1998).

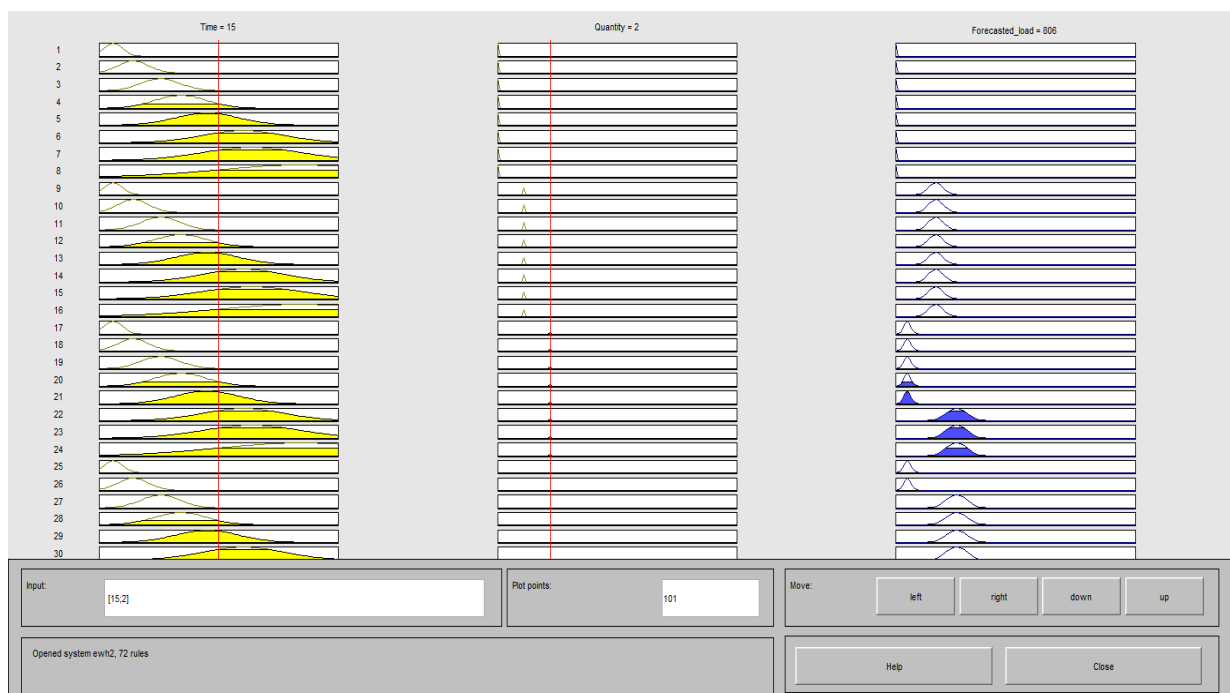


Figura 4.9 - Processo de *defuzzificação* (entradas e saída do modelo).

d) SIF: considerando união em tempo e quantidade de banhos

O tratamento dos dados considerando a união em tempo e quantidade de banhos quando eles tenham mais de 4,9 min, foi como explicado previamente. Entretanto, nesse caso, alguns dados e valores mudaram. Por essa razão, foram estabelecidas as funções de pertinência com

outros valores, como se apresenta para as entradas na Tabela 4.6 e saída na Tabela 4.7. Já em relação ao SIF (Regras e inferência), não houve alteração.

Tabela 4.6 - Funções de pertinência para a quantidade de banhos e o tempo de banho (união).

Nome	Descrição da variável	Dados estatísticos
MMB	Tempo de banho muito, muito baixo	$\mu = 1,80 \text{ min}; \sigma = 1,17 \text{ min}$
MB	Tempo de banho muito baixo	$\mu = 4,42 \text{ min}; \sigma = 1,90 \text{ min}$
B	Tempo de banho baixo	$\mu = 7,49 \text{ min}; \sigma = 2,46 \text{ min}$
N	Tempo de banho normal	$\mu = 8,80 \text{ min}; \sigma = 3,28 \text{ min}$
A	Tempo de banho alto	$\mu = 1,12 \text{ min}; \sigma = 3,96 \text{ min}$
MA	Tempo de banho muito alto	$\mu = 16,15 \text{ min}; \sigma = 5,12 \text{ min}$
MMA	Tempo de banho muito, muito alto	$\mu = 18,00 \text{ min}; \sigma = 6,20 \text{ min}$
S	Tempo de banho, superior	$\mu = 23,28 \text{ min}; \sigma = 10,30 \text{ min}$
Nd	Sem banhos	Nenhum
MMB	Quantidade de banhos muito, muito baixa	1 banho
MB	Quantidade de banhos muito baixa	2 banhos
B	Quantidade de banhos baixa	3 banhos
N	Quantidade de banhos normal	4 banhos
A	Quantidade de banhos alta	5 banhos
MA	Quantidade de banhos muito alta	6 banhos
MMA	Quantidade de banhos muito, muito alta	7 banhos
S	Quantidade de banhos superior	Acima de 8 banhos

Tabela 4.7 - Função de pertinência para a saída de previsão de carga (união).

Nome	Descrição da variável	Dados estatísticos (Potência no intervalo de uma hora)
Nd	Consumo zero	$\mu = 0; \sigma = 0$
CMMB	Consumo muito, muito baixo	$\mu = 200,00 \text{ W}; \sigma = 58,54 \text{ W}$
CMB	Consumo muito baixo	$\mu = 598,70 \text{ W}; \sigma = 121,00 \text{ W}$
CB	Consumo baixo	$\mu = 956,70 \text{ W}; \sigma = 172,00 \text{ W}$
CN	Consumo normal	$\mu = 1710,00 \text{ W}; \sigma = 246,10 \text{ W}$
CA	Consumo alto	$\mu = 1714,00 \text{ W}; \sigma = 316,00 \text{ W}$
CMA	Consumo muito alto	$\mu = 2090,00 \text{ W}; \sigma = 369,00 \text{ W}$
CMMA	Consumo muito, muito alto	$\mu = 2403,00 \text{ W}; \sigma = 314,00 \text{ W}$
CS	Consumo superior	$\mu = 2958,00 \text{ W}; \sigma = 400,00 \text{ W}$

e) Previsão das curvas de carga

Para determinar se as previsões tinham os resultados esperados foi desenvolvido um algoritmo que tinha os seguintes passos, no Matlab.

1. *Tratamento dos dados*: os dados foram tratados em intervalos de uma hora e em faixas de uma semana. Para isso, foi feito um algoritmo que permitiu esse tratamento básico dos dados.
2. *Sistema de Inferência Fuzzy (SIF) no Matlab*: foram estabelecidas as funções de pertinência de entrada e de saída e as regras do SIF. Esse processo inclui a *fuzzificação* e a *defuzzificação* das entradas e a integração entre os programas *Matlab* e *Simulink*.
3. *Previsão em Matlab*: encontra-se a curva de carga média para cada chuveiro, para a abordagem tradicional e para a lógica *Fuzzy*.

Em relação ao algoritmo 3, ele visa construir a curva de carga média usando a abordagem tradicional de curvas de carga e abordagem *Fuzzy*, dada pela equação (30).

$$Demanda_{i,d,h} = Média(Potência Consumida)_{i,d,h} \quad (30)$$

Onde:

i = corresponde ao eletrodoméstico (geladeira, chuveiro ou lâmpada).

d = dia de medição para um período de sete dias.

h = hora, incluindo os minutos (a taxa de amostras das medições é de 5 min).

As curvas construídas permitem comparar as duas abordagens, tradicional e *Fuzzy*. Abaixo descrevem-se as simulações feitas para as amostras.

f) Simulações

As simulações para a modelagem *Fuzzy* foram feitas conforme descrito abaixo.

1. A amostragem de controle foi dividida em duas partes, antes e depois da troca do chuveiro. O modelo SIF foi construído com os dados antes da troca do chuveiro.
2. Nos dados depois da troca do chuveiro, na amostra de controle, foi aplicado o modelo SIF.
3. Nas amostragens 2 e 3 foi aplicado o SIF.
4. No CERC, na aplicação do SIF, foi considerada a redução da potência, que no caso do chuveiro foi reduzida a 3000 W. Esse procedimento foi feito nas amostragens 2 e 3, considerando a redução da potência do chuveiro nas simulações. No entanto, as funções de pertinência foram inalteradas.

4.2.2 Modelagem usando a RNA

O *Perceptron* multicamada (MLP; do inglês, *Multilayer Perceptron*) é uma rede neural clássica (WARWICK, 1997), mas com uma camada a mais de neurônios. As redes MLP¹⁷ são uma das redes neuronais mais usadas em aplicações práticas (KHASHEI; BIJARI, 2012). Na Figura 4.10 é apresentada a arquitetura usada nas simulações. A MLP usada contém três

¹⁷ *Multilayer feedforward networks*

camadas. Na entrada, têm-se dois neurônios, que correspondem ao tempo de banho e à quantidade de banhos por hora; na camada intermediária, têm-se 50 neurônios; e, finalmente, na camada de saída tem-se um neurônio, que corresponde à previsão da curva de carga.

Cada sinal de entrada x_i é enviado a todos os neurônios da camada intermediária Y^1 . A cada neurônio da camada intermediária é atribuído um peso $W_i^{Y^1}$. Esse peso é calculado de acordo com o algoritmo BP (como explicado no Capítulo 3). O valor agregado que vai para cada neurônio da camada intermediária é a soma dos produtos de cada peso por entrada mais a função de ativação, que produz uma saída Y em cada camada. Dessa forma, são calculadas as saídas de Y^i . Logo, esses sinais são distribuídos a todos os neurônios da camada de saída, conforme apresentado na Figura 4.10.




Figura 4.10 - Arquitetura da rede neural usada (FFNN) para a previsão das curvas de carga.

Matematicamente na rede neural, as entradas correspondem ao tempo e à quantidade de banhos. A representação matemática da saída da rede é apresentada nas equações (31) a (34), abaixo.

$$y^1 = f^1(IW^{1,1}x_i + b^1) \quad (31)$$

$$y^2 = f^2(IW^{2,1}y^1 + b^2) \quad (32)$$

$$y^3 = f^3(IW^{3,1}y^2 + b^3) \quad (33)$$

$$y = f^3(LW^{3,2}f^2(LW^{2,1}f^1(IW^{1,1}X_i + b^1) + b^2) + b^3) \quad (34)$$

Onde X_i são as entradas, W_i são os pesos associados entre a entrada e a camada intermediária e b corresponde à função de ativação.

Foram feitos diversos testes para a seleção da rede neural que apresentasse a melhor solução. Nesse sentido foram selecionados os parâmetros a seguir, como os melhores para a arquitetura da rede neural, como se apresenta na Tabela 4.8.

Tabela 4.8 - Parâmetros da RNA.

Ação	No Matlab	Dado
Camada intermediária, usando o algoritmo BP.	<code>net = newff(inputs,pot_med1,50)</code>	50 neurônios
Iterações	<code>net.trainParam.epochs</code>	3000 períodos
Tolerância	<code>net.trainParam.goal</code>	0,00001
Treinamento dos dados	<code>net = train(net,inputs,pot_med1);</code>	Dados da amostragem 1 antes da troca do CE.

a) *Treinamento e erro da RNA*

O treinamento da rede foi feito com a função de otimização *Levenberg-Marquadt* (LM) (ILONEN; KAMARAINEN; LAMPINEN, 2003) para o algoritmo BP, na arquitetura da rede neural. Para o treinamento usaram-se os dados da amostra antes da troca do chuveiro da amostragem 1. Os dados do treinamento da RNA correspondem a dados por hora para uma semana. Em resumo, os dados de treinamento são as duas entradas (6216 x2 dados) e a saída (6216 dados). O procedimento para tratamento dos dados de entrada e de saída do modelo é similar ao que foi feito com a lógica *Fuzzy*. O algoritmo de otimização LM calcula o *Root-Mean-Square Error* (RMSE), de acordo com a equação (35). Para tanto, também foi utilizado o software Matlab (MATHWORKS; WANG, 1998).

$$RMSE = \frac{1}{N} \sum_{i=1}^N \sqrt{(y_{im}^i - y_{ip}^i)^2} \quad (35)$$

Onde y_m corresponde à potência medida e y_{ip} corresponde à potência prevista.

Além disso, o algoritmo de otimização calcula a eficiência do modelo, usando o R^2 , conforme a equação (36).

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_{im}^i - y_{ip}^i)^2}{\sum_{i=1}^N (y_{im}^i - y_{médio}^i)^2} \quad (36)$$

b) Simulações

As simulações para a modelagem com a RNA foram feitas conforme descrito abaixo.

1. A amostragem controle foi dividida em duas partes, antes e depois da troca do chuveiro. A rede neural foi treinada com os dados obtidos antes da troca do chuveiro.
2. A RNA foi aplicada aos dados obtidos após a troca do chuveiro para fazer a previsão.
3. A RNA também foi aplicada aos dados das amostragens 2 e 3 para fazer a previsão.
4. Para aplicação do SIF aos dados do CERC (amostragens 2 e 3), considerou-se a redução da potência que, neste caso, baixou para 3000 W.

4.3 Resultados e aplicações das abordagens *Fuzzy* e RNA às amostras – Etapa 5

Nesta seção, serão apresentados os resultados da aplicação da metodologia proposta usando as modelagens SIF e RNA. Apresentam-se resultados e análise do erro das previsões, assim como resultados dos PEEs para as amostras relativas aos dois casos estudados, CECET e CERC.

4.3.1 O caso do chuveiro elétrico com controlador de temperatura (CECET)

a) Previsão das curvas de demanda na Amostragem 1.

A seguir, é apresentada a aplicação da metodologia desenvolvida aos dados da amostragem 1 (Avaliação das abordagens SIF e RNA para o CECET). A amostragem 1

contém dados das medições do consumo de energia elétrica de chuveiros instalados em 37 residências, no âmbito do PEE da cidade de Volta Redonda. Essas residências passaram por uma medição antes da troca dos CEs, no período de 9 a 15 de setembro de 2013, e após a troca por CECETs, no período de 18 a 24 de setembro, totalizando uma semana de medição antes e uma semana depois da troca. Essa medição permitiu fazer uma caracterização do consumo de energia elétrica.

A Figura 4.11 e a Figura 4.12 mostram os resultados da previsão do SIF e da RNA, para os casos de aproximação e de união. Essas duas curvas foram desenvolvidas considerando dias úteis da semana e dias do fim de semana. As duas curvas de carga apresentam o mesmo comportamento no consumo, sendo que a partir das seis da manhã, o consumo de energia elétrica aumentou, progressivamente, até um primeiro pico, ao meio-dia. No período da tarde, em torno das 16h, o consumo caiu a um valor mínimo e, no fim da tarde, começa novamente a aumentar, sendo o pico de demanda às 19h. Isso aconteceu antes e depois da troca de chuveiro.




Figura 4.11 - Previsão da curva de carga antes e depois da inserção do CECET na amostragem 1 (aproximação).




Figura 4.12 - Previsão da curva de carga antes e depois da inserção do CECET na amostragem 1 (união).

b) Análise do erro para as abordagens SIF e RNA: aproximação em tempo de banho.

Para as previsões feitas com as modelagens usando as abordagens SIF e RNA anteriormente apresentadas, foram calculados os testes do EAM e EMPA. Na Figura 4.13 os resultados dos testes EAM e EMPA estão divididos em erros mínimos, médios e máximos. Os resultados que serão discutidos nesta seção correspondem às médias, porque elas permitem validar melhor a precisão da previsão. Antes da troca do CE usando o SIF na previsão, as médias dos erros foram de 5,6 W e 5,5%, para o EAM e o EMPA, respectivamente. Com a RNA foram de 4,3 W e 3,6% para o EAM e o EMPA, respectivamente. Esses resultados mostram uma melhoria na previsão de 1,8% em relação ao EMPA, quando do uso da RNA em comparação à previsão do SIF. Após a troca para o CECET, no caso do SIF, a média dos erros EAM e EMPA foram de 6,8 W e 8,2%, respectivamente. No caso da RNA, a média dos EAM e EMPA foram de 4,7 W e 5,4%, respectivamente. Novamente, houve melhoria, neste caso de 2,8% na previsão usando a RNA, quando comparada à previsão do SIF.

Em relação aos picos de demanda, os primeiros picos foram de 352,9 W (*ex-ante*) e 194,0 W (*ex-post*). A demanda máxima medida foi de 474,3 W (*ex-ante*) e 333,2 W (*ex-post*). Para a amostra obtida durante os picos, as previsões usando o SIF são mais adequadas e apresentam maior grau de precisão que as previsões com a RNA.




Figura 4.13 - Erro na amostra 1 caso CECET (aproximação): (a) EAM; (b) EMPA.

c) Análise do erro para as abordagens SIF e RNA: união em tempo de banho.

No tratamento de dados considerando a união em tempos e quantidade de banhos, antes da troca do CE usando o SIF na previsão, as médias foram de 6,0 W e 5,6%, para o EAM e o EMPA, respectivamente. De acordo com a Figura 4.14 para a RNA, as previsões foram de 4,8 W e 3,9% para o EAM e o EMPA, respectivamente. Esses resultados mostram uma melhoria na previsão de 1,8% usando a RNA com o EMPA, quando comparados à previsão do SIF. Após troca pelo CECET, no caso do SIF, as médias do EAM e do EMPA foram de 6,2 W e 8,11%, respectivamente. No caso da RNA, as médias do EAM e do EMPA foram de 6,9 W e 6,3%, respectivamente. Isso representou novamente uma melhoria, neste caso de 1,0%, na previsão usando a RNA. Em termos gerais, os resultados das simulações usando os dois procedimentos, tanto a aproximação, como a união, são semelhantes. Os resultados de EAM e EMPA também são semelhantes.




Figura 4.14 - Erro na amostragem 1, caso CECET (união). (a) EAM; (b) EMPA.

d) Análise da demanda máxima

De acordo com a Tabela 4.9, no primeiro pico *ex-ante*, o EMPA foi de 5,2% com o SIF e 3,0% com a RNA. No caso *ex-post*, foi de 3,8% no SIF e 3,4% na RNA. Em relação à demanda máxima *ex-ante*, o EMPA foi de 3,4% no SIF e 3,5% na RNA. No caso *ex-post*, foi de 0,1% no SIF e 1,6% na RNA. Essa tabela mostra que as duas abordagens são adequadas nas previsões, já que o EMPA das mesmas está abaixo de 5%.

Tabela 4.9 - Erro EAM e EMPA para a previsão do primeiro pico e máxima demanda na amostragem 1, caso CECET.

Item previsto	Método	Amostragem 1	EAM (W)	EMPA (%)
Primeiro pico	SIF	<i>ex-ante</i>	14,5	5,2
Primeiro pico	RNA	<i>ex-ante</i>	8,1	3,0
Primeiro pico	SIF	<i>ex-post</i>	7,2	3,8
Primeiro pico	RNA	<i>ex-post</i>	6,3	3,4
Demanda máxima na ponta	SIF	<i>ex-ante</i>	15,9	3,4
Demanda máxima na ponta	RNA	<i>ex-ante</i>	17,3	3,5
Demanda máxima na ponta	SIF	<i>ex-post</i>	0,4	0,1
Demanda máxima na ponta	RNA	<i>ex-post</i>	5,4	1,6

4.3.2 O caso do chuveiro elétrico com recuperador de calor (CERC)

a) Previsão das curvas de demanda da Amostragem 2

Na amostragem 2, foram medidos os consumos de energia elétrica em 23 residências no período *ex-ante*, entre 9 e 15 de setembro de 2013 e, no período *ex-post*, entre 18 e 24 de setembro de 2013. As modelagens das abordagens SIF e RNA foram feitas a partir dos dados da Amostragem 1 e, posteriormente, foram empregados na Amostragem 2, antes e depois da instalação do CERC. Neste caso foi considerada uma potência máxima de 3000 W, potência correspondente ao CERC. Os resultados das previsões são apresentados na Figura 4.15 e na Figura 4.16.




Figura 4.15 - Previsão da curva de carga antes e depois da inserção do CERC na amostragem 2 (aproximação).




Figura 4.16 - Previsão da curva de carga antes e depois da inserção do CERC recuperador de calor na amostragem 2 (união).

b) Análise do erro para as abordagens SIF e RNA: aproximação em tempo de banho.

Na Figura 4.17, podem-se observar as previsões feitas para o SIF e a RNA. Antes da troca do chuveiro, usando a modelagem SIF, as médias do EAM e do EMPA foram de 18,2 W e 9,0 %, respectivamente. No caso da modelagem da RNA, a média do EAM foi de 15,7 W e do EMPA, foi de 5,6%. Para este caso, a RNA faz uma previsão 3,4% melhor que o SIF. Depois da troca do CE pelo CERC usando a abordagem SIF, o EAM e o EMPA foram de 8,2 W e 6,8%, respectivamente. Já com a abordagem da RNA o EAM foi de 17,6 W e o EMPA foi de 3,8%. Neste caso, na RNA os resultados também trouxeram uma melhora de 3,01% na previsão em comparação ao SIF. Na Figura 4.17, mostram-se todos os erros calculados para o SIF e a RNA na amostragem 2, dividido em colunas, como foi explicado anteriormente.

Na amostragem 2, o primeiro pico (*ex-ante*) foi de 280,7 W e a demanda máxima na ponta (*ex-ante*) foi de 401,9 W. Com o CERC, o primeiro pico (*ex-post*) foi de 194,0 W e a demanda máxima na ponta (*ex-post*) foi de 333,3 W. A modelagem usando a RNA apresenta melhores resultados em comparação com a modelagem SIF. Em resumo, com a RNA, a previsão foi de 0,3%, para demanda máxima na ponta com o CE (*ex-ante*). Já com CERC (*ex-post*), a previsão foi de 2,7%, resultado muito próximos ao das medições. Isso permite concluir que a RNA é um método bom para este tipo de previsões.




Figura 4.17 - Erro na amostragem 2, caso CERC (aproximação). (a) EAM; (b) EMPA.

c) Análise do erro para as abordagens SIF e da RNA: união em tempo de banho.

No tratamento de dados considerando a união em tempos e quantidade de banhos, antes da troca do CE, usando o SIF na previsão, as médias foram de 9,9 W e 11,3%, para o EAM e o EMPA, respectivamente. De acordo com a Figura 4.18, com o SIF a previsão foi de 9,9W para o EAM e 12,1% para o EMPA. Em relação à RNA, a previsão foi de 7,3 W e 10,9% para o EAM e o EMPA, respectivamente. Após a substituição pelo CERC, no caso do SIF, a média do EAM e do EMPA foram de 5,2 W e 9,4%, respectivamente. No caso da RNA, as médias do EAM e do EMPA foram de 3,9 W e 5,8%, respectivamente.

Neste caso, de acordo com a Figura 4.18 o EAM e o EMPA também mostram melhores resultados usando a RNA. Em síntese as duas abordagens, SIF e RNA, são complementares, visto que os resultados são semelhantes como mostram os erros obtidos.




Figura 4.18 - Erro na amostragem 2, caso CERC (união). (a) EAM; (b) EMPA.

d) Análise da demanda máxima

Em relação às previsões nos picos de demanda, no primeiro pico (*ex-ante*) com o SIF, o EMPA foi de 13,3%, enquanto com a RNA, foi de 5,3%. Em relação ao período *ex-post*, com o SIF o EMPA foi de 20,6%, enquanto com a RNA, foi de 0,5%. Para a demanda máxima *ex-ante*, o EMPA foi de 7,9% e 0,3% para o SIF e a RNA, respectivamente. No período *ex-post*, o EMPA foi de 2,3% e 2,7% para o SIF e a RNA, respectivamente. No caso da amostragem 2, nos picos de demanda a RNA foi melhor nas previsões que o SIF, sendo essas previsões muito próximas aos valores medidos, como apresentado na Tabela 4.10.

Tabela 4.10 - EAM e EMPA para a previsão do primeiro pico e máxima demanda na amostragem 2, caso CERC.

Item previsto	Método	Amostragem 2	EAM (W)	MAPE (%)
Primeiro pico	SIF	<i>ex-ante</i>	37,3	13,3
Primeiro pico	RNA	<i>ex-ante</i>	14,2	5,3
Primeiro pico	FIS	<i>ex-post</i>	5,58	20,6
Primeiro pico	RNA	<i>ex-post</i>	0,5	0,5
Demanda maxima na ponta	SIF	<i>ex-ante</i>	31,6	7,9
Demanda maxima na ponta	RNA	<i>ex-ante</i>	1,2	0,3
Demanda maxima na ponta	SIF	<i>ex-post</i>	4,3	2,3
Demanda maxima na ponta	RNA	<i>ex-post</i>	5,2	2,7

a) Previsão das curvas de demanda na Amostra 3

Na amostragem 3, correspondente ao PEE feito na cidade de Rio de Janeiro, foram medidas 15 residências, antes e após a troca do chuveiro, no período *ex-ante*, compreendido entre 3 e 6 de junho de 2013 e *ex-post*, compreendido entre 17 e 23 de junho de 2013. As medições desta amostragem correspondem à cidade do Rio de Janeiro, em uma estação do ano diferente das duas primeiras amostragens. Na Figura 4.19, observam-se os resultados das previsões obtidas pelo SIF e pela RNA.




Figura 4.19 - Previsão da curva de carga antes e depois da inserção do recuperador de calor na amostragem 3, caso CERC.

b) Análise do erro para as abordagens SIF e RNA: aproximação em tempo de banho.

Na Figura 4.20, são apresentados o EAM e o EMPA das previsões das curvas de carga da amostragem 3. No período *ex-ante*, usando o SIF o EAM foi de 18 W e o EMPA de 20%. Já com a RNA, os erros foram de 15,7 W e 15,8 % para o EAM e o EMPA, respectivamente. Com base nesse resultado, a RNA apresentou previsão cerca de 4,0% melhor que o SIF. No período *ex-post*, com o CERC, no caso do SIF, a média do EAM foi de 8,1 W e do EMPA foi de 14,9%. Já com a RNA, o EAM foi de 17,0 W e o EMPA foi de 29,0%. Nesse caso, a

previsão do SIF foi 14,1% melhor que a da RNA, em relação ao EMPA. O primeiro pico da demanda medido *ex-ante* foi 144,0 W, às 12h, e a demanda máxima foi 273,6W. Já com o CERC (*ex-post*), foram 147,1 W no primeiro pico e 172,5 W na demanda máxima. Na amostragem 3, no primeiro pico as previsões não foram muito boas. Já em relação à demanda máxima, as previsões foram melhores.




Figura 4.20 - Erro na amostragem 3, caso CERC. (a) EAM; (b) EMPA.

d) Análise da demanda máxima

Na Tabela 4.11 as previsões no primeiro pico no período *ex-ante* usando o SIF o erro EMPA foi de 17,1% e com a RNA foi de 14,9%, no período *ex-post* usando o SIF o erro EMPA foi de 26,4% e com a RNA foi de 14,8%. A demanda máxima *ex-ante* no SIF foi de 6,4% e com a RNA foi de 9,3%. No período *ex-post* no SIF 6,6% e com a RNA 9,7%. Em resumo na amostra 3 as previsões com o RNA foram melhores em comparação com o SIF.

Tabela 4.11. Erro EAM e EMPA para a previsão do primeiro pico e máxima demanda na amostragem 3, caso CERC.

Item previsto	Método	Amostragem 3	EAM (W)	EMPA (%)
Primeiro pico	SIF	<i>ex-ante</i>	29,7	17,1
Primeiro pico	RNA	<i>ex-ante</i>	21,4	14,9
Primeiro pico	SIF	<i>ex-post</i>	52,77	26,4
Primeiro pico	RNA	<i>ex-post</i>	21,78	14,8
Demanda maxima na ponta	SIF	<i>ex-ante</i>	17,5	6,4
Demanda maxima na ponta	RNA	<i>ex-ante</i>	28	9,3
Demanda maxima na ponta	SIF	<i>ex-post</i>	11,8	6,6
Demanda maxima na ponta	RNA	<i>ex-post</i>	16	9,7

4.3.3 Normalização das curvas para o CECET e o CERC

Nesta tese, foram desenvolvidas curvas normalizadas para comparar as duas tecnologias de chuveiros elétricos. Têm-se três curvas, a primeira curva foi construída considerando todas

as amostras; a segunda curva corresponde ao controlador de temperatura; e a terceira curva corresponde ao recuperador de calor. Na Figura 4.21, apresentam-se os resultados da normalização das curvas. A normalização das curvas foi feita sobre uma base de 500 W. As previsões das curvas de carga podem ser usadas pelas concessionárias de energia elétrica, como base para tomada de decisões relacionadas a investimentos nos PEEs e ações de GLD.




Figura 4.21 - Comparação entre CE (*ex-ante*), CECET (*ex-post*) e CERC (*ex-post*).

Comparando-se as três curvas da Figura 4.21, observa-se que a redução na demanda máxima com controlador de temperatura não é tão eficaz na ponta. Entretanto, a economia de energia é evidente. No caso do recuperador de calor, houve redução tanto na demanda máxima, como no primeiro pico. Além disso, houve uma economia de energia maior em todos os períodos do dia. Na curva normalizada para o chuveiro elétrico sem substituição, a demanda às 12h foi aproximadamente de 0,46 p.u., enquanto que com o controlador de temperatura, essa demanda foi reduzida para 0,38 p.u. Em relação aos resultados do recuperador de calor (usado nas amostragens 2 e 3), o primeiro pico e a demanda máxima foram reduzidos de 0,46 p.u. para 0,26 p.u. e de 0,68 p.u. para 0,37 p.u., respectivamente. Isso mostra que houve redução importante.

4.3.4 Resultados dos PEEs da ANEEL nas amostras

Nesta seção são apresentados os resultados dos PEEs nas amostras estudadas. Inicialmente será apresentada a economia de energia, posteriormente, dados quantitativos e estatísticos em relação à potência e o tempo em cada um dos PEEs desenvolvidos

a) Economia de energia na amostragem 1

Na Figura 4.22 observa-se que em cinco residências não ocorreu economia de energia elétrica. Não obstante, esse consumo não aumentou acima de 12%. Nas 32 residências restantes, apresentou-se economia de energia. Destacando-se 4 famílias que obtiveram uma redução superior a 50% por meio do PEE. Em síntese, o consumo total de energia nos 37 domicílios foi reduzido de 500,1 kWh para 393,4 kWh em uma semana, o que representa uma redução de 27,1% no consumo de energia. Pode-se observar que os CECETs possibilitam uma economia no consumo de energia, visto que os usuários conseguem ajustar a temperatura do banho e, conseqüentemente, o consumo de energia por meio do PEE.




Figura 4.22 - Economia de energia elétrica na amostragem 1. a) CE antes da troca e b) CECET.

b) Classificação do tempo e a potência na amostragem 1

Na tabela 4.12 são apresentados a distribuição dos dados em função da potência. Nesta tabela, os resultados mais relevantes serão listados a seguir. No CE na faixa menor a 365 W houve 172 banhos, o que corresponde a 15,05%; na faixa entre 2750 e 3000 W, houve 192 banhos, o que corresponde a 11,2% dos banhos; na faixa entre 366 e 731 W, ocorreram 366 banhos, o que corresponde a 32,04% dos banhos; na parte intermediária da potência na faixa entre 1097 e 1461 W, ocorreram 158 banhos, o que corresponde a 13,83% dos banhos; na faixa entre 1462 e 1826 W ocorreram 66 banhos, o que corresponde a 5,77% dos banhos; na faixa superior entre 1827 e 2191 W houve 46 banhos, o que corresponde a 4,02 % dos banhos; na faixa entre 2192 e 2555 W ocorreram 25 banhos, o que corresponde a 2,18% dos banhos, na faixa entre 2556 e 2920 W houve 16 banhos, o que corresponde a 1,40% dos banhos.

No caso do CECET em relação à distribuição da potência; na faixa menor a 325 W houve 219 banhos o que corresponde a 22,46% dos banhos, na faixa seguinte entre 325 e 650 W ocorreram 350 banhos o que corresponde a 35,90% dos banhos; e na faixa entre 651 e 976 W houve 268 banhos o que corresponde a 27,49%, nas faixas seguintes vai se reduzindo o número de banhos, destacando-se o deslocamento na potência para as primeiras faixas com o CECET.

Tabela 4.12. Distribuição dos banhos na amostragem 1 em potência com CE e o CECET.

Potência (W)	Número de banhos	Porcentagem (%)	Potência (W)	Número de banhos	Porcentagem (%)
Antes			Depois		
< 365	172	15,06	< 325	219	22,46
Entre 366 e 731	366	32,04	Entre 325 e 650	350	35,90
Entre 732 e 1096	290	25,39	Entre 651 e 976	268	27,49
Entre 1097 e 1461	158	13,83	Entre 977 e 1627	82	8,41
Entre 1462 e 1826	66	5,77	Entre 1628 e 1952	28	2,87
Entre 1827 e 2191	46	4,02	Entre 1953 e 2277	17	1,74
Entre 2192 e 2555	25	2,18	Entre 2278 e 2602	4	0,41
Entre 2556 e 2920	16	1,40	Entre 2603 e 2928	5	0,51
Entre 2921 e 3650	3	0,26	Entre 2929 e 3253	2	0,21
Total	1142	100	Total	975	100

De acordo com a Tabela 4.13 em relação ao tempo de banho, as faixas do CE foram divididas em tempos de 5 minutos, destacando-se o consumo das primeiras três faixas: menor a 5 minutos 594 banhos o que corresponde a 51,79%; entre 5 e 10 minutos 345 banhos o que corresponde a 30,08%; e entre 10 e 15 minutos 120 banhos o que corresponde a 10,46% dos banhos. No que diz respeito do CECET os tempos se concentraram principalmente nas duas primeiras faixas; menor a 5 minutos, houve 541 banhos o que corresponde a 48,96% e entre 5 e 10 minutos, houve 120 banhos o que corresponde a 30,08%.

Em resumo, comparando-se os resultados apresentados na Figura 4.23 e na Figura 4.24, é possível observar que ocorreu um deslocamento na potência e no tempo de banho com o uso do CECET.

Tabela 4.13 - Distribuição dos banhos na amostragem 1 no tempo com CE e o CECET.

Tempo (min)	Número de banhos	Porcentagem (%)	Tempo (Min)	Número de banhos	Porcentagem (%)
Antes			Depois		
< 5	594	51,79	< 5	541	48,96
Entre 5 e 10	345	30,08	Entre 5 e 10	319	28,87
Entre 10 e 15	120	10,46	Entre 10 e 15	143	12,94
Entre 15 e 20	48	4,18	Entre 15 e 20	58	5,25
Entre 20 e 25	28	2,44	Entre 20 e 25	31	2,81
Entre 25 e 30	12	1,05	Entre 25 e 30	13	1,18
Total	1147	100	Total	1105	100




Figura 4.23- Histogramas da potência e quantidade de banhos na amostragem 1: a) CE e b) CECET.




Figura 4.24- Histogramas do tempo e quantidade de banhos na amostragem 1: a) CE e b) CECET.

c) Economia de energia na amostragem 2

Em relação à economia de energia na amostragem 2, no caso do CE, o consumo total de energia, nos 23 domicílios, foi de 278,1 kWh. Após a inserção do CERC, o consumo foi de 137,8 kWh, o que representou uma redução de 50,1%. Cabe ressaltar que o uso do CERC não permite, ao usuário, controlar a temperatura da água de banho de forma independente.

Quanto à economia de energia elétrica, pode-se observar por meio da Figura 4.25, que somente na residência 16, não se apresentou uma economia de energia. Nesta residência, houve um acréscimo de 8,9% no consumo em decorrência do aumento no número de banhos. Nas 22 residências restantes, o consumo foi reduzido, com uma economia de energia acumulada de 50,4%.

Um aspecto positivo do CERC foi que em 12 das 23 residências, a economia de energia foi superior a 50%. Destacando-se a residência 17, com uma economia de 85,3%. Em síntese, o consumo de energia elétrica foi reduzido de 278,06 kWh para 137,86 kWh.




Figura 4.25 - Economia de energia elétrica na amostragem 2. a) CE antes da troca e b) CERC.

d) Classificação do tempo e a potência na amostragem 2

A Tabela 4.14 apresenta os resultados da distribuição de banhos da amostragem 2 com o CE e o CERC. Nesta tabela, os resultados mais relevantes serão listados a seguir com o CE os dados se distribuem principalmente entre 0 e 1544 W. Na faixa menor a 387 W houve 186 banhos o que corresponde a 26,38%; na faixa entre 388 e 773 W ocorreram 255 banhos o que corresponde a 36,17%; na faixa entre 774 e 1158 W houve 137 banhos o que corresponde a 19,43%; e na faixa entre 1159 e 1544 W ocorreram 87 banhos o que corresponde a 12,34% dos banhos. Com o CERC os dados são deslocados para valores de potência abaixo de 621 W. Na faixa menor a 225 W houve 127 banhos o que corresponde a 25,05%; na faixa entre 226 e 423 W ocorreram 170 banhos o que corresponde a 33,53% dos banhos; por último na faixa entre 423 e 621 W houve 140 banhos o que corresponde a 27,61% dos banhos.

Tabela 4.14. Distribuição dos banhos na amostra 2 em potência com CE e o CERC

Potência (W)	Número de banhos	Porcentagem (%)	Potência (W)	Número de banhos	Porcentagem (%)
Antes			Depois		
< 387	186	26,38	< 225	127	25,05
Entre 388 e 773	255	36,17	Entre 226 e 423	170	33,53
Entre 774 e 1158	137	19,43	Entre 423 e 621	140	27,61
Entre 1159 e 1544	87	12,34	Entre 622 e 1018	33	6,51
Entre 1545 e 1929	29	4,11	Entre 1019 e 1215	32	6,31
Entre 1930 e 2314	10	1,42	Entre 1216 e 1612	3	0,59
Entre 2314 e 3085	1	0,14	Entre 1613 e 2009	2	0,39
Total	705	100	Total	507	100

Em relação ao tempo de banho com o CE os tempos de banho encontra-se principalmente em tempos inferiores a 18,5 minutos. Na faixa menor a 4,6 minutos houve a maioria dos banhos 359 o que corresponde a 50,49%; na faixa entre 4,7 e 9,3 minutos ocorreram 204 banhos o que corresponde a 28,69%. No CERC os banhos se concentraram principalmente em tempos menores a 10 minutos, na faixa menor a 5 minutos houve 285 banhos o que corresponde a 47,50%; e na faixa entre 5 e 10 minutos ocorreram 203 banhos o que corresponde a 33,83%, resultados apresentados na Tabela 4.15.

Em resumo, comparando-se os resultados apresentados da distribuição dos dados no histograma na Figura 4.26 e na Figura 4.27 mostram um deslocamento na potência por uso da menor resistência do CERC.

Tabela 4.15 - Distribuição dos banhos na amostra 2 no tempo com CE e o CERC.

Tempo (min)	Número de banhos	Porcentagem (%)	Tempo (Min)	Número de banhos	Porcentagem (%)
Antes			Depois		
< 4,6	359	50,49	< 5	285	47,50
Entre 4,7 e 9,3	204	28,69	Entre 5 e 10	203	33,83
Entre 9,4 e 13,8	97	13,64	Entre 10 e 15	62	10,33
Entre 13,9 e 18,5	31	4,36	Entre 15 e 20	25	4,17
Entre 18,6 e 23,2	17	2,39	Entre 20 e 25	17	2,83
Entre 23,3 e 30	3	0,42	Entre 25 e 30	8	1,33
Total	711	100	Total	600	100




Figura 4.26- Histogramas da potência e quantidade de banhos na amostragem 2: a) CE e b) CERC.




Figura 4.27- Histogramas do tempo e quantidade de banhos na amostragem 2: a) CE e b) CERC.

e) Economia de energia na amostragem 3

No caso do CE, tem-se um consumo total de energia, nos 15 domicílios, de 137,5 kWh. Após a implementação do CERC, o consumo mudou para 90,12 kWh, o que representa uma redução de 34,5%, como pode ser observado na Figura 4.28. Para a amostragem 3, houve mudança nos horários de pico dos consumidores antes e após a troca do chuveiro. Antes da troca do chuveiro, o primeiro pico se apresentou às 13h, com demanda de 149,2 W e a demanda máxima (273,7 W) ocorreu às 21h. Com a troca do chuveiro, tanto a primeira demanda, como a demanda máxima, tiveram seus horários deslocados para 12h e 19h, respectivamente, tendo se tornado semelhantes aos das amostragens 1 e 2. Além disso, houve redução de 33.9% na demanda máxima na ponta.




Figura 4.28 - Economia de energia eléctrica na amostragem 3. a) CE antes da troca e b) CERC.

f) Classificação do tempo e da potência na amostragem 3

Na Tabela 4.16 os resultados em relação à potência no CE a maioria dos banhos se concentram nas três primeiras faixas. Na faixa menor a 331 W houve 124 banhos o que corresponde a 31,96%; na faixa entre 332 e 603 W ocorreram 126 banhos o que corresponde a 32,46%; na faixa entre 604 e 875 W houve 114 banhos o que corresponde a 29,38%. Em total nessas três primeiras faixas encontram-se 93,81% dos banhos. No CERC os banhos se concentraram principalmente nas faixas entre 160 e 320 W, nessa faixa houve 114 banhos o que corresponde a 14% e na faixa entre 321 e 479 W ocorreram 159 banhos o que corresponde a 33,47%.

Tabela 4.16- Distribuição dos banhos na amostra 3 em potência com CE e o CERC.

Potência (W)	Número de banhos	Porcentagem (%)	Potência (W)	Número de banhos	Porcentagem (%)
Antes			Depois		
< 331	124	31,96	< 160	58	12,21
Entre 332 e 603	126	32,47	Entre 160 e 320	114	14,00
Entre 604 e 875	114	29,38	Entre 321 e 479	159	33,47
Entre 876 e 1419	18	4,64	Entre 480 e 639	42	8,84
Entre 1420 e 1962	2	0,52	Entre 640 e 797	52	10,95
Entre 1963 e 2234	2	0,52	Entre 798 e 957	27	5,68
Entre 2235 e 2506	1	0,26	Entre 958 e 1116	11	2,32
Entre 2507 e 2778	1	0,26	Entre 1117 e 1275	3	0,63
			Entre 1276 e 1435	9	1,89
			Entre 1436 e 1593	1	0,21
Total	388	100	Total	475	100

Em relação ao tempo de banho na Tabela 4.17 apresentam-se os resultados da distribuição na amostragem 3. No CE a maioria dos banhos 86,38% concentram-se nas faixas: menor a 4,2 minutos; e entre 4,2 e 8,4 minutos. Nessa faixa menor a 4,2 minutos houve 258 banhos o que corresponde a 57,59%; na faixa entre 4,2 e 8,4 minutos ocorreram 129 banhos o que corresponde a 28,79%. No caso do CECET a maioria dos banhos se concentraram na faixa menor a 4,8 minutos houve 286 banhos o que corresponde a 60,08%.

Tabela 4.17. Distribuição dos banhos na amostra 3 no tempo com CE e o CERC.

Tempo (min)	Número de banhos	Porcentagem (%)	Tempo (Min)	Número de banhos	Porcentagem (%)
Antes			Depois		
< 4,2	258	57,59	< 4,8	286	60,08
Entre 4,2 e 8,4	129	28,79	Entre 4,8 e 9,5	121	25,42
Entre 8,4 e 12,5	41	9,15	Entre 9,6 e 14,3	49	10,29
Entre 12,6 e 16,7	10	2,23	Entre 14,4 e 19,1	13	2,73
Entre 16,8 e 20,9	7	1,56	Entre 19,2 e 23,9	5	1,05
Entre 21 e 25	3	0,67	Entre 24 e 30	2	0,42
Total	448	100	Total	476	100

Em resumo, comparando-se os resultados, antes com CE e após a troca pelo CERC na amostragem 3 da Figura 4.29 e a Figura 4.30 observa-se um deslocamento na potência do chuveiro em diferentes faixas. Em contraste o tempo de banho aumentou com o uso de CERC. É importante mencionar que os dados usados nesta amostras foram poucos em relação com os dados das outras amostragens.




Figura 4.29. Histogramas da potência e quantidade de banhos na amostragem 3: a) CE e b) CERC.




Figura 4.30. Histogramas do tempo e quantidade de banhos na amostragem 2: a) CE e b) CERC.

4.4 Resumo dos resultados dos PEEs (união)

Na Tabela 4.18, é apresentado um resumo dos resultados dos PEEs. Na amostragem 1, o consumo foi reduzido em 27,1% e o tempo de banho em 7,1%. Ainda com relação à amostragem 1, os resultados mostram um maior efeito na economia de energia usando o CERC, quando comparado ao CECET. Em relação à amostragem 2, a economia de energia foi de 50% e o tempo de banho foi reduzido em 6,7%. Já na amostragem 3, o consumo foi reduzido em 34% e o tempo de banho aumentou em 13,2%.

Tabela 4.18. Resumo dos efeitos dos PEEs na economia de energia e no tempo.

	Consumo de energia	Porcentagem de economia de energia	Tempo de banho	Porcentagem de redução do tempo de banho
CE (Amostra 1)	500,1 kWh		6,44 minutos	
CECET (Amostra 1)	393,4 kWh	27,1%	5,98 minutos	7,1%
CE (Amostra 2)	278,1 kWh		5,96 minutos	
CERC (Amostra 2)	137,8 kWh	50%	5,60 minutos	6,7%
CE (Amostra 3)	137,5 kWh		4,52 minutos	
CERC (Amostra 2)	90,1 kWh	34%	5,12 minutos	-13,2%

5 CONCLUSÕES E SUGESTÕES PARA PRÓXIMOS TRABALHOS

5.1 Conclusões

Neste trabalho, foram desenvolvidos modelos de previsão a partir de duas abordagens, *Fuzzy* e RNAs, para a obtenção de curvas de carga em CEs. A metodologia desenvolvida permitiu (i) fazer previsões de curvas de carga nos PEEs estudados; (ii) determinar e calcular o erro das previsões; (iii) avaliar o impacto na economia de energia das duas tecnologias, CECET e CERC, usadas nos PEEs do Brasil; e (iv) implementar a metodologia para avaliar previamente o impacto da troca dos CEs nos PEEs implementados nas comunidades.

As conclusões do trabalho foram:

1. Foi proposta uma metodologia para a obtenção de curvas de carga nos chuveiros elétricos usando as abordagens *Fuzzy* e RNAs.
2. Foi desenvolvido um modelo de previsão a partir de dois procedimentos (aproximação e união). Os dois métodos permitiram obter de forma adequada e apropriada a curva de carga.
3. A metodologia desenvolvida permite (1) fazer previsões de curvas de carga nos PEEs da ANEEL para os CEs; (2) determinar e calcular o erro das previsões; (3) avaliar o impacto na economia de energia das duas tecnologias, CECET e CERC, usadas nos PEEs; e (4) implementar a metodologia para avaliar previamente o impacto da troca dos CEs nos PEEs nas comunidades de baixa renda.
4. Os resultados mostram que a RNA, em termos gerais, tem melhores previsões em comparação com a abordagem *Fuzzy*. Na amostragem 1, tanto usando a aproximação, como usando a união de tempos, o EMPA nas previsões usando a RNA, ficou entre 3% e 6% e, usando o SIF, ficou entre 5% e 9%. Na amostragem 2, o EMPA nas previsões usando a RNA ficou entre 4% e 6% e, usando o SIF, ficou entre 6% e 9%. Usando a união de tempos na amostragem 2, nas previsões do SIF, o EMPA ficou entre 3% e 7%. Já em relação à RNA, o EMPA ficou entre 3% e 11%. Finalmente, na amostragem 3, o SIF teve melhores previsões, apresentando erro entre 15% e 20%, ao

passo que a RNA apresentou erro entre 15% e 20%.

5. Em relação à previsão da demanda máxima, as duas abordagens são adequadas, tanto no primeiro pico como na demanda máxima na ponta. Na amostragem 1, a melhor previsão no primeiro pico foi de 3% e, na demanda máxima na ponta, foi de 0,4% com a RNA e com o SIF, respectivamente. Já na amostragem 2, no primeiro pico, foi de 0,5% e, na demanda máxima na ponta, foi de 1,2%, usando a RNA. Enquanto que na amostragem 3, no primeiro pico, foi de 14,8% e, na demanda máxima na ponta, foi de 11,8%, usando a RNA e o SIF, respectivamente. Esses resultados mostram que tanto o SIF como a RNA conseguem capturar as rápidas mudanças existentes nos horários de máxima demanda por parte dos consumidores.
6. Os dois principais objetivos dos PEEs, de acordo com a resolução normativa 300 de 2008, são a economia de energia e a redução da demanda na ponta. A partir da avaliação desses PEEs, em relação à substituição dos CEs, obtiveram-se os seguintes resultados. Na amostragem 1, a economia de energia foi de 27,09% e a redução da demanda máxima na ponta foi de 29,74%; na amostragem 2, a economia de energia foi de 50,49% e a redução da demanda máxima na ponta foi de 51,67%; e na amostragem 3, a economia de energia foi de 34,47% e a redução da demanda máxima na ponta foi de 33,94%.
7. Foram construídos gráficos 3D que permitiram identificar a distribuição de banhos e a quantidade de banhos. Além disso, foram calculadas as porcentagens da distribuição de banhos nas amostras. Todas essas análises foram feitas antes e depois da troca dos CEs. Esses resultados mostraram, de forma gráfica, o impacto dos CECET e CERC nos PEEs, em relação à influência desses aparelhos no consumo de energia elétrica.
8. Na amostragem 1, com os CEs antes da troca, a média do tempo de banho foi de 6,44 minutos e após a troca pelo CECET, a mediana foi de 5,98 minutos, ocorrendo uma redução de 7,1%. Na amostragem 2, com os CEs antes da troca, a média do tempo de banho foi de 5,96 minutos e após a troca pelo CERC, a mediana foi de 5,60 minutos, ocorrendo uma redução de 6,7%. Por último, na amostragem 3, com os CEs antes da troca, a mediana do tempo de banho foi de 4,52 minutos e, após a troca pelo CERC, a mediana foi de 5,12 minutos, apresentando-se um acréscimo na mediana de 13,2%.

Atualmente, os modelos de previsão de curvas de carga a curto e médio prazo, são fundamentais na operação e no planejamento dos sistemas de distribuição. Nesse sentido, a metodologia desenvolvida na tese pode ser aplicada pelos tomadores de decisão, para fazer previsões do impacto dos PEEs da ANEEL, na substituição de CEs por CECETs e CERCs, nas comunidades de baixa renda no Brasil.

As abordagens usadas neste trabalho são práticas e flexíveis. Elas permitem a modelagem de variáveis relacionadas ao tempo e à quantidade de banhos para fazer a previsão das curvas de carga. Desse modo, essas duas variáveis podem ser usadas em comunidades que apresentem condições socioeconômicas similares. Além disso, o modelo usado no presente trabalho é simples e fácil de implementar de modo prático. O uso da metodologia desenvolvida durante esse trabalho pode contribuir com reduções nos custos logísticos relacionados aos PEEs nas comunidades de baixa renda, em regiões de difícil acesso, permitindo avaliar previamente os possíveis impactos desses programas.

A aplicação de métodos baseados na Inteligência Artificial é prática e requer poucas informações, sendo ótima na aplicação de casos práticos como previsão da demanda de carga.

5.2 Limitações deste trabalho

O presente estudo tem algumas limitações, listadas abaixo.

1. O número de amostragens, que foi reduzido para três.
2. As medições, que estão limitadas pelo número de dias das medições, e a qualidade das mesmas.
3. A literatura existente relacionada com previsão de curvas de carga em chuveiros elétricos é escassa, assim como a literatura relacionada com previsões a partir dos hábitos das pessoas.

5.3 Sugestões para próximos trabalhos

Com a tese desenvolvida, surgem perguntas e questionamentos para trabalhos futuros que continuem a avaliação e análises dos PEEs desenvolvidos no Brasil. Portanto, outros estudos e pesquisas fazem-se necessários. Dentre os possíveis temas para pesquisas futuras, podem-se destacar

1. Extensão da metodologia para outros aparelhos, como geladeiras e lâmpadas, atualmente usados nos PEEAs no Brasil.
2. Revisar outros tipos de técnicas que possam fazer previsões das curvas de carga.
3. Levantamento de informações sobre os hábitos dos consumidores, que permitam a modelagem de dados com maior detalhe e execução de previsões sobre mudanças nesses hábitos.

Referências

ACEEE. **Appliance Labeling**. Disponível em: <<http://aceee.org/topics/appliance-labeling>>. Acesso em: 22 fev. 2017.

AGOSTINI, C. A.; SAAVEDRA, E.; PLOTTIER, C. **La demanda residencial por energía eléctrica en Chile**. 2011. Disponível em: <http://www.uai.cl/RePEc/uai/wpaper/wp_013.pdf>. Acesso em: 10 nov. 2016.

AKDEMIR, B.; ÇETINKAYA, N. **Long-term load forecasting based on adaptive neural fuzzy inference system using real energy data**. Energy Procedia, v. 14, p. 794–799, 2012.

AL-FUHAID, A. S.; EL-SAYED, M. A.; MAHMOUD, M. S. **Neuro-short-term load forecast of the power system in Kuwait**. Applied Mathematical Modelling, v. 21, n. 4, p. 215–219, 1997.

AL-KANDARI, A. M.; SOLIMAN, S. A.; EL-HAWARY, M. E. **Fuzzy short-term electric load forecasting**. International journal of electrical power & energy systems, v. 26, n. 2, p. 111–122, 2004.

ALMEIDA, A. *et al.* **Residential monitoring to decrease energy use and carbon emissions in Europe**. International Energy Efficiency in Domestic Appliances & Lighting Conference. Anais 2006. Disponível em: <http://www.isr.uc.pt/~remodece/news/Paper_DeAlmeida.pdf>. Acesso em: 30 out. 2015.

ALMEIDA, M. A.; SCHAEFFER, R.; LA ROVERE, E. L. **The potential for electricity conservation and peak load reduction in the residential sector of Brazil**. Energy, v. 26, n. 4, p. 413–429, 2001.

ANEEL - **Agência Nacional de Energia Elétrica**. Disponível em: <<http://www.aneel.gov.br/area.cfm?idArea=550>>. Acesso em: 30 nov. 2015.

ANEEL. **Resolução Normativa 300 de 2008**. Disponível em: <<http://www.aneel.gov.br/arquivos/PDF/ren2008300.pdf>>. Acesso em: 22 fev. 2016.

ANEEL. **Resolução Normativa 556 de 2013**. [s.d.]. Disponível em: <<http://www2.aneel.gov.br/aplicacoes/audiencia/arquivo/2012/073/resultado/ren2013556.pdf>>. Acesso em: 21 fev. 2017.

ANEEL. **Resolução Normativa 407 de 2010**. Federal - LegisWeb. Disponível em: <<https://www.legisweb.com.br/legislacao/?id=112880>>. Acesso em: 23 fev. 2017.

ANEEL. **Resolução Normativa 456 e 485 de 2008** [s.d.]. Disponível em: <<http://www2.aneel.gov.br/arquivos/PDF/Minutas%20para%20disponibilizar.pdf>>. Acesso em: 23 fev. 2017.

BADRI, A.; AMELI, Z.; BIRJANDI, A. M. **Application of artificial neural networks and fuzzy logic methods for short term load forecasting**. Energy Procedia, v. 14, p. 1883–1888, 2012.

BAJAY, S. V. **Long-term electricity demand forecasting models: a review of methodologies**. Electric power systems research, v. 6, n. 4, p. 243–257, 1983.

BAKIRTZIS, A. G. *et al.* **Short term load forecasting using fuzzy neural networks**. Power Systems, IEEE Transactions on, v. 10, n. 3, p. 1518–1524, 1995.

BALIYAN, A.; GAURAV, K.; MISHRA, S. K. **A Review of Short Term Load Forecasting using Artificial Neural Network Models**. Procedia Computer Science, v. 48, p. 121–125, 2015.

BARILOCHE, C.; INGENIEROS, B. R. P. **Consultoría para la formulación estratégica del plan de uso racional de energía y de fuentes no convencionales de energía 2007-2025**. UPME. Bogotá 2007.

BARUNÍK, J.; MALINSKA, B. **Forecasting the term structure of crude oil futures prices with neural networks**. Applied Energy, v. 164, p. 366–379, 2016.

BEN. **Relatório Final BEN 2015**. [s.d.]. Disponível em: <https://ben.epe.gov.br/downloads/Relatorio_Final_BEN_2015.pdf>. Acesso em: 22 fev. 2016.

BENEDETTI, M. *et al.* **Energy consumption control automation using Artificial Neural Networks and adaptive algorithms: Proposal of a new methodology and case study**. Applied Energy, v. 165, p. 60–71, 2016.

BIEE. Base de Indicadores de Eficiência Energética. Disponível em: <<http://www.cepal.org/drni/biee>> Acesso em: 20 nov. 2015.

BORG, S. P.; KELLY, N. J. **The effect of appliance energy efficiency improvements on domestic electric loads in European households**. *Energy and Buildings*, v. 43, n. 9, p. 2240–2250, 2011.

BUILDINGS EUROPEAN COMMISSION. Disponível em: <<https://ec.europa.eu/energy/en/topics/energy-efficiency/buildings>>. Acesso em: 23 nov. 2016.

CARPIO, C.; COVIELLO, M. **Eficiencia energética en América Latina y el Caribe: avances y desafíos del último quinquenio**. 2013. Disponível em : <<http://www.cepal.org/es/publicaciones/4106-eficiencia-energetica-america-latina-caribe-avances-desafios-ultimo-quinquenio>> . Acesso em: 10 dez. 2016.

CASTRO, T. **Análise do Impacto do Chuveiro Elétrico em Redes de Distribuição no Contexto da Tarifa Horosazonal**. **Tese de Mestrado em Engenharia Elétrica FEEC**. UNICAMP. 2014.

CHING, F. D.; WINKEL, S. R. **Building Codes Illustrated: A Guide to Understanding the 2015**. *International Building Code*. [s.l.] John Wiley & Sons, 2016.

CHOW, J. H.; WU, F. F.; MOMOH, J. A. **Applied mathematics for restructured electric power systems**. [s.l.] Springer, 2005.
Come on Labels. [s.d.]. Disponível em: <https://www.energyagency.at/fileadmin/dam/pdf/publikationen/berichteBroschueren/comeon_labels_vergleich.pdf>. Acesso em: 23 fev. 2017.

Creative Research Systems. **Sample size calculator: Confidence level, confidence interval, sample size, population size, Relevant Population**. Disponível em: <<http://www.surveysystem.com/sscalc.htm>>. Acesso em: 1 nov. 2016.

PIMVP-COMMITTEE. **International Performance Measurement and Verification Protocol: Concepts and Options for Determining Energy and Water Savings**. Volume I. [s.l.] National Renewable Energy Lab., Golden, CO (US), 2001. Disponível em: <<http://www.osti.gov/scitech/biblio/776003>>. Acesso em: 1 jun. 2016.

DE PAULA FALCO, G. **O perfil econômico do consumidor residencial de energia elétrica no período entre 1994-2003**. [s.d.]. Disponível em: <http://portal.viannajunior.edu.br/files/uploads/20131001_101008.pdf> Acesso em: 10 nov. 2016.

DE SILVA, C. W. **Intelligent control: fuzzy logic applications**. [s.l.] CRC press, 1995.

DORIS, E.; COCHRAN, J.; VORUM, M. **Energy efficiency policy in the United States: overview of trends at different levels of government**. [s.l.] National Renewable Energy Laboratory, US Department of Energy, Office of Energy Efficiency and Renewable Energy, 2009.

ECOSHOWER. **Chuveiros Elétricos**. Informações disponíveis no site Disponível em: <<http://www.ecoshower.com.br/>> Acesso em: 12 jun. 2015.

EPE. **Anuário estatístico de energia elétrica**. Empresa de Pesquisa Energética, 2015. Disponível em: <<http://www.epe.gov.br/AnuarioEstatisticodeEnergiaEletrica/Forms/Anurio.aspx>> Acesso em: 5 jan. 2016.

EM&V. **Evaluation, Measurement and Verification**. Disponível em: <<http://aceee.org/topics/evaluation-measurement-and-verification-emv>>. Acesso em: 23 fev. 2017.

ENERGY GUIDE. **Consumer Information**. Disponível em: <<https://www.consumer.ftc.gov/articles/0072-shopping-home-appliances-use-energyguide-label>>. Acesso em: 22 fev. 2017.

ENERGY STAR. **The simple choice for energy efficiency**. Disponível em: <<https://www.energystar.gov/>>. Acesso em: 22 fev. 2017.

EXCEL. **Microsoft Office Excel 2007**. Software 2017.

EVO. EFFICIENCY VALUATION ORGANIZATION. **Protocolo Internacional de Medição e Verificação de Performance**. Conceitos e Opções para a Determinação de Economias de Energia e de Água, v. 1. EVO 2012 (Brasil).

FARAHBAKHS, H.; UGURSAL, V. I.; FUNG, A. S. **A residential end-use energy consumption model for Canada**. International Journal of Energy Research, v. 22, n. 13, p. 1133–1143, 1998.

FEDRIGO, N. S.; GHISI, E.; LAMBERTS, R. **Usos Finais de Energia Elétrica no Setor Residencial Brasileiro**. ENCONTRO NACIONAL DE CONFORTO NO AMBIENTE CONSTRUÍDO, v. 10, p. 367–376, 2009.

FIRTH, S. *et al.* **Identifying trends in the use of domestic appliances from household electricity consumption measurements.** *Energy and Buildings*, v. 40, n. 5, p. 926–936, 2008.

FIRTH, S. K.; LOMAS, K. J.; WRIGHT, A. J. **Targeting household energy-efficiency measures using sensitivity analysis.** *Building Research & Information*, v. 38, n. 1, p. 25–41, 2010.

FLEITER, T.; WORRELL, E.; EICHHAMMER, W. **Barriers to energy efficiency in industrial bottom-up energy demand models - a review.** *Renewable and sustainable energy reviews*, v. 15, n. 6, p. 3099–3111, 2011.

FOLEY, A. M. *et al.* **A strategic review of electricity systems models.** *Energy*, v. 35, n. 12, p. 4522–4530, 2010.

FUMO, N. **A review on the basics of building energy estimation.** *Renewable and Sustainable Energy Reviews*, v. 31, p. 53–60, 2014.

GRAM-HANSSSEN, K. **Efficient technologies or user behavior, which is the more important when reducing households' energy consumption?.** *Energy Efficiency*, v. 6, n. 3, p. 447–457, 2013.

GOMEZ, R. PACCOLA, J. JANNUZZI, R. MELO, C. **Medição de consumo de eletricidade e demanda para refrigeradores domésticos no brasil: um estudo de caso para três comunidades de baixa renda.** Disponível em: <http://eluree.org/wp-content/uploads/2013/09/actas/GT1%20pdf/3%20-%20GT1_Gomes_3037%20-%20final.pdf>. Acesso em: 21 jun. 2016.

GRANADE, H. C. *et al.* **Unlocking energy efficiency in the US economy.** 2009.

GRANDJEAN, A.; ADNOT, J.; BINET, G. **A review and an analysis of the residential electric load curve models.** *Renewable and Sustainable Energy Reviews*, v. 16, n. 9, p. 6539–6565, 2012.

GREENBLATT, J. *et al.* **Energy use of US residential refrigerators and freezers: function derivation based on household and climate characteristics.** *Energy Efficiency*, v. 6, n. 1, p. 135–162, 2013.

HAINOUN, A. **Construction of the hourly load curves and detecting the annual peak load of future Syrian electric power demand using Bottom-up approach.** International Journal of Electrical Power & Energy Systems, v. 31, n. 1, p. 1–12, 2009.

HARMELINK, M.; JOOSEN, S.; BLOK, K. **The theory-based policy evaluation method applied to the ex-post evaluation of climate change policies in the built environment in the Netherlands.** Proceedings of the ECEEE. Anais...2005 Disponível em: <https://www.researchgate.net/profile/Kornelis_Blok/publication/46675610_The_theory-based_policy_evaluation_method_applied_to_the_ex-post_evaluation_of_climate_change_policies_in_the_built_environment_in_the_Netherlands/links/0c960521b09ad578ce000000.pdf>. Acesso em: 25 out. 2016.

HARRINGTON, L.; WILKENFELD, G. **Appliance efficiency programs in Australia: labelling and standards.** Energy and Buildings, v. 26, n. 1, p. 81–88, 1997.

HAYKIN, S.; NETWORK, N. **A comprehensive foundation. Neural Networks.** Vol. 2, n. 2004, 2004.

HERBST, A. *et al.* **Introduction to energy systems modelling.** Swiss journal of economics and statistics, v. 148, n. 2, p. 111–135, 2012.

HILLER, C. **Influence of residents on energy use in 57 Swedish houses measured during four winter days.** Energy and buildings, v. 54, p. 376–385, 2012.

HIPPERT, H. S.; PEDREIRA, C. E.; SOUZA, R. C. **Neural networks for short-term load forecasting: A review and evaluation.** IEEE Transactions on power systems, v. 16, n. 1, p. 44–55, 2001.

HOLLANDER, E.; ROSER, A. **Energy Efficient Appliances for Low-Income Households.** [s.d.]. Disponível em: <http://www.irees.de/irees-wAssets/docs/publications/proceeding/eedal15_submission_140.pdf> Acesso em: 10 oct. 2016.

HORTA NOGUEIRA, *et al.* **Indicadores de políticas públicas en materia de eficiencia energética en América Latina y el Caribe.** 2010. Disponível em: <<http://www.cepal.org/es/publicaciones/3763-indicadores-politicas-publicas-materia-eficiencia-energetica-america-latina>> Acesso em: 8 sep. 2016.

HUANG, Y. J.; BRODRICK, J. **A bottom-up engineering estimate of the aggregate heating and cooling loads of the entire US building stock.** Lawrence Berkeley National Laboratory, 2000.

IBGE. **Instituto Brasileiro de Geografia e Estatística.** Disponível em: <<http://www.ibge.gov.br/home/estatistica/populacao/condicaodevida/indicadoresminimos/sinteseindicais2010/>>. Acesso em: 30 out. 2015.

IBGE. **Instituto Brasileiro de Geografia e Estatística.** Disponível em: <ftp://ftp.ibge.gov.br/Orcamentos_Familiares/Pesquisa_de_Orcamentos_Familiares_2008_2009/Perfil_das_Despesas_no_Brasil/tabelas_pdf/tab_1_02.pdf>. Acesso em: 21 fev. 2017

IGLESIAS FURFARO, H. **Eficiencia energética: Programa Nacional de Uso Racional y Eficiente de la Energía (PRONUREE).** Seminario Eficiencia Energética: Diagnóstico, Incentivos e Instituciones. FIEL/ALADEE/UCA, 2012.

ILONEN, J.; KAMARAINEN, J.-K.; LAMPINEN, J. **Differential evolution training algorithm for feed-forward neural networks.** Neural Processing Letters, v. 17, n. 1, p. 93–105, 2003.

INMETRO. **Tabelas de consumo-eficiência energética.** Disponível em: <<http://www.inmetro.gov.br/consumidor/tabelas.asp>>. Acesso em: 23 fev. 2017.

INTELLIGENT **ENERGY EUROPE.** Disponível em: <<https://ec.europa.eu/energy/intelligent/projects>>. Acesso em: 5 nov. 2015.

JANG, J.-S. R.; SUN, C.-T.; MIZUTANI, E. **Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence.** 1997.

JANNUZZI, G. D. M.; SCHIPPER, L. **The structure of electricity demand in the Brazilian household sector.** Energy Policy, v. 19, n. 9, p. 879–891, 1991.

JIANG, J. **China's urban residential carbon emission and energy efficiency policy.** Energy, v. 109, p. 866–875, 2016.

JIANG, J. **China's urban residential carbon emission and energy efficiency policy.** Energy, v 109, p. 866–875.

KANDIL, M. S.; EL-DEBEIKY, S. M.; HASANIEN, N. E. **Long-term load forecasting for fast developing utility using a knowledge-based expert system.** IEEE Transactions on Power Systems, v. 17, n. 2, p. 491–496, 2002.

KAR, S.; DAS, S.; GHOSH, P. K. **Applications of neuro fuzzy systems: A brief review and future outline.** Applied Soft Computing, v. 15, p. 243–259, 2014.

KAVGIC, M. *et al.* **A review of bottom-up building stock models for energy consumption in the residential sector.** Building and environment, v. 45, n. 7, p. 1683–1697, 2010.

KHANNA, N. Z. *et al.* **Evaluation of China's local enforcement of energy efficiency standards and labeling programs for appliances and equipment.** Energy policy, v. 63, p. 646–655, 2013.

KHASHEI, M.; BIJARI, M. **Hybridization of the probabilistic neural networks with feed-forward neural networks for forecasting.** Engineering Applications of Artificial Intelligence, v. 25, n. 6, p. 1277–1288, 2012.

KHOTANZAD, A.; AFKHAMI-ROHANI, R.; MARATUKULAM, D. **ANNSTLF - artificial neural network short-term load forecaster generation three.** Power Systems, IEEE Transactions on, v. 13, n. 4, p. 1413–1422, 1998.

KIALASHAKI, A.; REISEL, J. R. **Modeling of the energy demand of the residential sector in the United States using regression models and artificial neural networks.** Applied Energy, v. 108, p. 271–280, 2013.

KIARTZIS, S. J.; BAKIRTZIS, A. G.; PETRIDIS, V. **Short-term load forecasting using neural networks.** Electric Power Systems Research, v. 33, n. 1, p. 1–6, 1995.

LAPILLONNE, B. *et al.* **Energy efficiency trends in buildings in the EU—lessons from the ODYSSEE MURE project.** ADEME. Retrieved December, v. 30, p. 2014, 2012.

LEE, C. C. **Fuzzy logic in control systems: fuzzy logic controller.** II. Systems, Man and Cybernetics, IEEE Transactions on, v. 20, n. 2, p. 419–435, 1990.

LEE, D. G.; LEE, B. W.; CHANG, S. H. **Genetic programming model for long-term forecasting of electric power demand.** Electric power systems research, v. 40, n. 1, p. 17–22, 1997.

LEI 10.438 de 2002. Disponível em: http://www.planalto.gov.br/ccivil_03/leis/2002/L10438.htm. Acesso em: 23 fev. 2017.

LEI 12.212 de 2010. Disponível em: http://www.planalto.gov.br/ccivil_03/_ato2007-2010/2010/lei/l12212.htm. Acesso em: 23 fev. 2017.

LEI 9.991 de 2000. Federal LegisWeb. Disponível em: <<https://www.legisweb.com.br/legislacao/?id=85453>>. Acesso em: 23 fev. 2017.

LIAO, G.-C.; TSAO, T.-P. **Application of fuzzy neural networks and artificial intelligence for load forecasting.** Electric Power Systems Research, v. 70, n. 3, p. 237–244, 2004.

LIHEAP. **Low income home energy assistance program.** Disponível em: <<https://liheap.hhs.gov/Funding/funding.htm>>. Acesso em: 18 oct. 2016.

LOCE, R. P.; DOUGHERTY, E. R. **Mean-absolute-error representation and optimization of computational-morphological filters.** Graphical Models and Image Processing, v. 57, n. 1, p. 27–37, 1995.

LOPES, M. L. M.; MINUSSI, C. R.; LOTUFO, A. D. P. **Electric load forecasting using a fuzzy ART&ARTMAP neural network.** Applied soft computing, v. 5, n. 2, p. 235–244, 2005.

MAHMOUD, T. *et al.* **Fuzzy Inference System in Energy Demand Prediction.** [s.l.] INTECH Open Access Publisher, 2012.

MAMDANI, E. H.; ASSILIAN, S. **An experiment in linguistic synthesis with a fuzzy logic controller.** International journal of man-machine studies, v. 7, n. 1, p. 1–13, 1975.

MAMLOOK, R. **Fuzzy set methodology for evaluating alternatives to compare between different power production systems.** Journal of Applied Sciences, v. 6, n. 9, p. 1686–1691, 2006.

MAMLOOK, R.; BADRAN, O.; ABDULHADI, E. **A fuzzy inference model for short-term load forecasting.** Energy Policy, v. 37, n. 4, p. 1239–1248, 2009.

MANDAL, P. *et al.* **A neural network based several-hour-ahead electric load forecasting using similar days approach.** International Journal of Electrical Power & Energy Systems, v. 28, n. 6, p. 367–373, 2006.

MATHWORKS, I.; WANG, W. **Fuzzy Logic Toolbox: for Use with MATLAB: User's Guide.** [s.l.] Mathworks, Incorporated, 1998.

MASON, E.; ASHER, E. **The World Bank since Bretton Woods.** Brookings Institution Press.

MCCULLOCH, W. S.; PITTS, W. **A logical calculus of the ideas immanent in nervous activity**. The bulletin of mathematical biophysics, v. 5, n. 4, p. 115–133, 1943.

MCNEIL, M. A. *et al.* **Bottom-Up Energy Analysis System (BUENAS)—an international appliance efficiency policy tool**. Energy Efficiency, v. 6, n. 2, p. 191–217, 2013.

MICHALIK, G. *et al.* **Structural modelling of energy demand in the residential sector: 1. Development of structural models**. Energy, v. 22, n. 10, p. 937–947, 1997.

MIN-CHILE. Ministério de Energia de Chile. Informações disponíveis no site Disponível em: <<http://www.energia2050.cl/>>. Acesso em: 10 jan. out. 2017

MOHAMAD, E. A. *et al.* **Results of Egyptian unified grid hourly load forecasting using an artificial neural network with expert system interface**. Electric power systems research, v. 39, n. 3, p. 171–177, 1996.

M&V - ANEEL. **Guia de Medição e Verificação para o Programa de Eficiência Energética Regulado pela Aneel. 2014.** Disponível em: <<http://www.light.com.br/Repositorio/Eficiencia-Energetica/Guia%20de%20MV.pdf>>. Acesso em: 21 fev. 2017.

NADEL, S. **Appliance and equipment efficiency standards in the US: accomplishments, next steps and lessons learned**. ECEEE 2002 Summer Study Proceedings, v. 1, p. 75–86, 2003.

NASPOLINI, H. F.; MILITÃO, H. S. G.; RÜTHER, R. **The role and benefits of solar water heating in the energy demands of low-income dwellings in Brazil**. Energy Conversion and Management, v. 51, n. 12, p. 2835–2845, 2010.

NATARAJAN, S.; PADGET, J.; ELLIOTT, L. **Modelling UK domestic energy and carbon emissions: an agent-based approach**. Energy and Buildings, v. 43, n. 10, p. 2602–2612, 2011.

NEJAT, P. *et al.* **A global review of energy consumption, CO 2 emissions and policy in the residential sector (with an overview of the top ten CO 2 emitting countries)**. Renewable and Sustainable Energy Reviews, v. 43, p. 843–862, 2015.

NGUYEN, H. T. *et al.* **A first course in fuzzy and neural control**. [s.l.] CRC press, 2002.

NOERGAARD, J. *et al.* **Turning the appliance market around towards A++**. ECEEE Summer Study Proceedings. Anais...ECEEE Secretariat, Stockholm, Sverige. 2007. Disponível em: <<http://www.forskningsdatabasen.dk/en/catalog/108119368>>. Acesso em: 25 out. 2016.

ODYSSEE-MURE. **Data Tools**. Disponível em: <<http://www.odyssee-mure.eu/data-tools/>>. Acesso em: 22 nov. 2016.

PANDIAN, S. C. *et al.* **Fuzzy approach for short term load forecasting**. Electric Power Systems Research, v. 76, n. 6, p. 541–548, 2006.

PAPALEXOPOULOS, A. D.; HAO, S.; PENG, T.-M. **An implementation of a neural network based load forecasting model for the EMS**. Power Systems, IEEE Transactions on, v. 9, n. 4, p. 1956–1962, 1994.

PASSOS, L.; CARDEMIL, J. M.; COLLE, S. **Feasibility Study of Using Domestic Solar Hot Water Systems as Alternative to Reduce the Electricity Peak Demand in Brazil**. Energy Procedia, v. 57, p. 2487–2495, 2014.

PEE-ANEEL. **Dados da ANEEL dos PEEs**. informações disponíveis no site <www.aneel.gov.br/arquivos/Excel/PEE%20Projetos.xls> Acesso em: 15 jun. 2017.

PENG, T. M.; HUBELE, N. F.; KARADY, G. G. **Advancement in the application of neural networks for short-term load forecasting**. Power Systems, IEEE Transactions on, v. 7, n. 1, p. 250–257, 1992.

PÉREZ-LOAMBARD, L. *et al.* **A review of HVAC systems requirements in building energy regulations**. Energy and Buildings, 43(2), 252-268.

PPEE. **Política de Eficiência Energética** [s.d.]. Disponível em: <<https://www.ppee.cl/2014/07/politica-de-eficiencia-energetica/>>. Acesso em: 23 fev. 2017.

POMPERMAYER, M. L. **Programa de eficiência energética das empresas de distribuição de energia elétrica-PEE**. [s.l.] AbineeTec, 2012.

POWERSAVE. **Medição de consumo de energia elétrica**. Disponível em: <<http://www.powersave.com.br/>> Acessado em: 5 mar. 2017.

PROCEL. **Programa Nacional de Conservação de Energia Elétrica**. Pesquisa de Posse de Equipamentos e Hábitos de Uso—Ano Base, 2005. Disponível em: <: <http://www.procelinfo.com.br/main.asp>> Acesso em: 10 nov. 2015.

ProPEE - ANEEL. **Procedimentos do Programa de Eficiência Energética - PROPEE** 2008. <http://www.aneel.gov.br/programa-eficiencia-energetica/>. Acesso em: 15 sep. 2016.

RAILIO, J. **Energy Performance of Buildings Directive (EPBD)**. Influences on European standardization and on ventilation and air-conditioning industry. Update and follow-up, v. 3, 2005.

REMME, U. *et al.* **MESAP/TIMES - advanced decision support for energy and environmental planning**. Operations Research Proceedings 2001. Anais...Springer, 2002. Disponível em: <http://link.springer.com/chapter/10.1007/978-3-642-50282-8_8>. Acesso em: 1 jun. 2016

REVISTA FAPESP. **Recuperador de Calor**. Disponível em: <<http://revistapesquisa.fapesp.br/2007/10/01/chuveiro-esperto/>> Acesso em: 1 oct. 2015.

RICHARDSON, I.; THOMSON, M.; INFELD, D. **A high-resolution domestic building occupancy model for energy demand simulations**. Energy and buildings, v. 40, n. 8, p. 1560–1566, 2008.

ROMERO RAMOS, N. P. **Consumo de Energía a Nivel Residencial en Chile y Análisis de Eficiencia Energética en Calefacción**. 2011.

SAD - ANEEL. **Base de Dados**. <<http://www2.aneel.gov.br/area.cfm?idArea=550>>. Acesso em: 25 sept. 2015.

SANCHEZ, I. *et al.* **Assessment of the Impacts of Standards and Labeling Programs in Mexico (four products)**. Lawrence Berkeley National Laboratory, 2007.

SENJYU, T.; HIGA, S.; UEZATO, K. **Future load curve shaping based on similarity using fuzzy logic approach**. IEE Proceedings-Generation, Transmission and Distribution, v. 145, n. 4, p. 375–380, 1998.

SHARMA, D. P.; NAIR, P. C.; BALASUBRAMANIAN, R. **Demand for commercial energy in the state of Kerala, India: an econometric analysis with medium-range projections**. Energy policy, v. 30, n. 9, p. 781–791, 2002.

SHORROCK, L. D.; DUNSTER, J. E. **The physically-based model BREHOMES and its use in deriving scenarios for the energy use and carbon dioxide emissions of the UK housing stock.** *Energy Policy*, v. 25, n. 12, p. 1027–1037, 1997.

SOARES, L. J.; MEDEIROS, M. C. **Modeling and forecasting short-term electricity load: A comparison of methods with an application to Brazilian data.** *International Journal of Forecasting*, v. 24, n. 4, p. 630–644, 2008.

SÖZEN, A.; ARCAKLIOĞLU, E.; ÖZKAYMAK, M. **Turkey's net energy consumption.** *Applied Energy*, v. 81, n. 2, p. 209–221, 2005.

STOKES, M. **Removing barriers to embedded generation: a fine-grained load model to support low voltage network performance analysis.** 2005.

SUGANTHI, L.; SAMUEL, A. A. **Energy models for demand forecasting—A review.** *Renewable and sustainable energy reviews*, v. 16, n. 2, p. 1223–1240, 2012.

SWAN, L. G.; UGURSAL, V. I. **Modeling of end-use energy consumption in the residential sector: A review of modeling techniques.** *Renewable and sustainable energy reviews*, v. 13, n. 8, p. 1819–1835, 2009.

SZKUTA, B. R.; SANABRIA, L. A.; DILLON, T. S. **Electricity price short-term forecasting using artificial neural networks.** *IEEE transactions on power systems*, v. 14, n. 3, p. 851–857, 1999.

TOLMASQUIM, M. T. **Perspectivas e planejamento do setor energético no Brasil.** *Estudos Avançados*, v. 26, n. 74, p. 247–260, 2012.

TRIPATHI, M. M.; UPADHYAY, K. G.; SINGH, S. N. **Short-term load forecasting using generalized regression and probabilistic neural networks in the electricity market.** *The Electricity Journal*, v. 21, n. 9, p. 24–34, 2008.

TURIEL, I. **Present status of residential appliance energy efficiency standards - an international review.** In: *Energy Efficiency in Household Appliances*. [s.l.] Springer, 1999. p. 43–54.

VAN BEECK, N. **Classification of energy models.** [s.l.] Tilburg University, Faculty of Economics and Business Administration, 1999.

WALKER, C. F.; POKOSKI, J. L. **Residential load shape modelling based on customer behavior**. Power Apparatus and Systems, IEEE Transactions on, n. 7, p. 1703–1711, 1985.

WARWICK, K. **Artificial intelligence techniques in power systems**. [s.l.] Iet, 1997.

WIDROW, B.; HOFF, M. E. **Adaptive switching circuits**. 1960.

WILKENFELD, G. **Benefits and Costs of Implementing Minimum Energy Performance Standards for Household Electrical Appliances in Australia**, Final Report. G. Wilkenfeld and Associates, Sofia Antipolis, France (April, 1993), 1993.

ZADEH, L. A. **Fuzzy sets**. Information and control, v. 8, n. 3, p. 338–353, 1965.

ZÚÑIGA, K. V.; CASTILLA, I.; AGUILAR, R. M. **Using fuzzy logic to model the behavior of residential electrical utility customers**. Applied Energy, v. 115, p. 384–393, 2014.

Anexo A – Atividades realizadas durante o doutorado

- Estágio de capacitação docente – PED B. Prof. Marco Lúcio Bittencourt.
- Artigo submetido à revista “International Transactions European Electrical System” **Fuzzy logic and neural networks for short term load forecasting: a technological comparison of electric showers** (2016).
- Artigo apresentado em Congresso ELEUREE. **Indicator EDI of energy consumption in low-income households in state of Rio de Janeiro** (Argentina, 2013).
- Artigo apresentado no Simpósio Brasileiro de Sistemas Elétricos. **Análise de preços de leilões de energia solar: avaliação probabilística** (Brasil, 2014).
- Artigo apresentado no Congresso Brasileiro de Planejamento Energético. **Economic estimate of power demand for Brazilian regions** (Brasil, 2014).
- Artigo apresentado no Congresso Brasileiro de Planejamento Energético. **PIR no setor rodoviário brasileiro: horizonte 2013 – 2030** (Brasil, 2014).

Anexo B – Principais algoritmos usados na tese

a) Obtenção de dados

```

clear all
close all
clc

[filename, pathname] = uigetfile({'*.xlsx'; '*.xls'}, 'Select a EXECL code
file');
if isequal(filename,0)
    disp('User selected Cancel');
else
    disp(['User selected ', fullfile(pathname, filename)])
end

list = dir([pathname, '/*.xls']);

nf=length(list);

cont1=0;

matriz_final=[];
for k=1:nf

    file = strcat(pathname,list (k).name);
    [NUMERIC]= xlsread(file);
    [n,m] = size(NUMERIC);
    cont = 1;

    % Matriz datos
    mat=NUMERIC;
    % Cantidad de eventos totales
    cons=mat(:,2);
    pot=mat(:,3);
    dur=mat(:,4);
    matriz=[cons pot dur]
    [N,M]=size(dur);
    dur_conteo=zeros(N,M);
    pot_nueva=zeros(N,M);
    cons_nueva=zeros(N,M);
    dur_nueva=zeros(N,M);
    format long
    dur_aux =2016;
    cont=0;
    for i=1:2016-1
        if(dur(i)> 0)
            if(dur(i)> 4.5)
                dur_conteo(i) =2;
                cont = 4.5;
            end
        end
    end
    matriz_final=[matriz; dur_conteo; pot_nueva; cons_nueva; dur_nueva];
end
close all
clc

```

```

        else
            dur_conteo(i)=1;
        end
    else
        dur_conteo(i)=0;
    end

    dur_conteo(i) ;

    if (dur(i)> 0)
        if (dur_conteo(i)==2) && (dur_aux>cont)

            %Potencia
            pot_nueva(i)=pot(i)+pot(i+1);
            pot(i)=0;
            pot(i+1)=pot_nueva(i);

            %Duración
            dur_nueva(i)=dur(i)+dur(i+1);
            dur_aux = dur(i+1);

            dur(i)=0;
            dur(i+1)=dur_nueva(i);

            %cons
            cons_nueva(i) = cons(i)+cons(i+1);
            cons(i)=0;
            cons(i+1) = cons_nueva(i);
            dur_conteo(i)=0;
        else
            dur_conteo(i)=1;
            dur_aux = 5;
        end
    end

    end

    matriz=[cons pot dur dur_conteo]

    aux=1
    for i=1:168

        cons_medias(i)=sum(cons(aux:12+aux-1,1));
        pot_medias(i)=sum (pot(aux:12+aux-1,1))/12;
        dur_medias(i)=sum(dur(aux:12+aux-1,1));
        dur_conteo_medias(i)=sum(dur_conteo(aux:12+aux-1,1));
        aux=aux+12

    end

    % Matriz com (168*nf,4) dados
    matriz_total=[cons_medias' pot_medias' dur_medias'
dur_conteo_medias']; % matriz_dur_conteo_medias'
    matriz_final = [matriz_final; matriz_total];

end

```



```

for i=1:a1
Error(i)= abs((total_graf_med(i)-total_graf_fuz(i))/total_graf_med(i))*100
end

%MAPE
M=sum(Error)/a1

t=1:24
plot(t,total_graf_med,'b')
hold on
plot(t,total_graf_fuz,'k')
grid
title('Previsão de demanda de energia elétrica nos chuveiros (W)')
xlabel('Tempo em horas')
ylabel('Potência (W)')
legend('Medição','Método Fuzzy')
axis([1 24 0 500])

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% ANALISES DE ERROS %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

%MAE
x_gerall=total_graf_med
y_gerall_Fuzzy=total_graf_fuz
MAE_gerall_Fuzzy=mean_avg(x_gerall,y_gerall_Fuzzy) % Mean Average Error
%Fuzzy
MAPE_gerall_Fuzzy=mean_perc(x_gerall,y_gerall_Fuzzy) % Mean Average Error
%Fuzzy

```

c) Red Neural

```

clear all
close all
clc

load dados_controle1
dados_controle1=matriz

matriz=[cons pot dur dur_conteo]

aux=1
for i=1:168

    cons_medias(i)=sum(cons(aux:12+aux-1,1));
    pot_medias(i)=sum (pot(aux:12+aux-1,1))/12;
    dur_medias(i)=sum(dur(aux:12+aux-1,1));
    dur_conteo_medias(i)=sum(dur_conteo(aux:12+aux-1,1));
    aux=aux+12

end

% Matriz com (168*nf,4) dados
matriz_total=[cons_medias' pot_medias' dur_medias'
dur_conteo_medias']; % matriz_dur_conteo_medias'
matriz_final = [matriz_final; matriz_total];

end

```

```
datos=matriz_final

pot2=datos(:,2)
dur2=datos(:,3)
conteo2=datos(:,4)

matriz_final;

matriz_para_excel=[dur2 conteo2]

pot22=pot2'
dur22=dur2'
conteo22=conteo2'

pot2_168_n=[]
dur2_168_n=[]
conteo2_168_n=[]

for i=0:nf-1
    pot2_168=pot22((i*168)+1):168*(i+1))
    pot2_168_n = [pot2_168_n; pot2_168];
    dur2_168=dur22((i*168)+1):168*(i+1))
    dur2_168_n = [dur2_168_n; dur2_168];
    conteo2_168=conteo22((i*168)+1):168*(i+1))
    conteo2_168_n = [conteo2_168_n; conteo2_168];
end

size(pot2_168_n)
size(dur2_168_n)
size(conteo2_168_n)

pot_168=pot2_168_n'
dur_168=dur2_168_n'
conteo_168=conteo2_168_n'

matriz_168= [pot_168 dur_168 conteo_168]
size(matriz_168)

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
% DATOS MEDIDOS %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

pot_med=[]
for i=1:24

pot_24_1=(pot_168(i,1:nf))+ (pot_168(i+24,1:nf))+(pot_168(i+48,1:nf))+(pot_168(i+72,1:nf))+(pot_168(i+96,1:nf))+(pot_168(i+120,1:nf))+(pot_168(i+144,1:nf));

    pot_24_n=pot_24_1./7
    pot_med=[pot_med; pot_24_n]
end

pot_med
```

```

matriz_168 = datos2

inputs = [datos2(:,3:4)]';
pot_med1 = [datos2(:,2)]';
nf1=37

%load Red
net = newff(inputs,pot_med1,50); % arquitectura backpropagation con 50
net.trainParam.epochs=3000; % iteracciones
net.trainParam.goal=0.00001; % tolerancia del error
net = train(net,inputs,pot_med1); % entrenamiento

pot_RN = net(inputs); % evaluacion de la red
errors = pot_RN - pot_med1; % calculo de error
perf = perform(net,pot_RN,pot_med1) % calculo de performance

pot_med22=pot_med1'
pot_RN22=pot_RN'

pot_med2_168_n1=[]
pot_RN2_168_n1=[]

for i=0:nf1-1

    pot_med2_168=pot_med22(((i*168)+1):168*(i+1))
    pot_med2_168_n1 = [pot_med2_168_n1 pot_med2_168];
    pot_RN2_168=pot_RN22(((i*168)+1):168*(i+1))
    pot_RN2_168_n1 = [pot_RN2_168_n1 pot_RN2_168];

end

pot_med2_168_n=pot_med2_168_n1'
pot_RN2_168_n=pot_RN2_168_n1'
size(pot_med2_168_n)
size(pot_RN2_168_n)

%Construindo a curva diária
pot_med_final=[]
pot_RN_final=[]
for i=1:24

    pot_24_med1=(pot_med2_168_n1(i,1:nf1))+(pot_med2_168_n1(i+24,1:nf1))+(pot_med2_168_n1(i+48,1:nf1))+(pot_med2_168_n1(i+72,1:nf1))+(pot_med2_168_n1(i+96,1:nf1))+(pot_med2_168_n1(i+120,1:nf1))+(pot_med2_168_n1(i+144,1:nf1));
    pot_24_med=pot_24_med1./7
    pot_med_final=[pot_med_final; pot_24_med]

    pot_24_RN1=(pot_RN2_168_n1(i,1:nf1))+(pot_RN2_168_n1(i+24,1:nf1))+(pot_RN2_168_n1(i+48,1:nf1))+(pot_RN2_168_n1(i+72,1:nf1))+(pot_RN2_168_n1(i+96,1:nf1))+(pot_RN2_168_n1(i+120,1:nf1))+(pot_RN2_168_n1(i+144,1:nf1));
    pot_24_RN=pot_24_RN1./7
    pot_RN_final=[pot_RN_final; pot_24_RN]

end

matriz_med=[]
matriz_RN=[]

```

```

for i=1:24
    matriz_med(i)=sum(pot_med_final(i,1:nf1))/nf1
    matriz_RN(i)=sum(pot_RN_final(i,1:nf1))/nf1
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% REDE TREINADA %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

inputs2 = [dados(:,3:4)]';
pot_RN_Am3 = net(inputs2);

pot_RN22_Am3=pot_RN_Am3'

pot_RN2_168_n1_Am3 =[]

nf=37

for i=0:nf-1

    pot_RN2_168_Am3=pot_RN22_Am3(((i*168)+1):168*(i+1))
    pot_RN2_168_n1_Am3 = [pot_RN2_168_n1_Am3 pot_RN2_168_Am3];

end

pot_RN2_168_n_Am3 =pot_RN2_168_n1_Am3
size(pot_RN2_168_n_Am3 )

%Construindo a curva diária

pot_RN_final_Am3=[]
    for i=1:24

        pot_24_RN1_Rec=(pot_RN2_168_n1_Am3 (i,1:nf))+(pot_RN2_168_n1_Am3
(i+24,1:nf))+(pot_RN2_168_n1_Am3 (i+48,1:nf))+(pot_RN2_168_n1_Am3
(i+72,1:nf))+(pot_RN2_168_n1_Am3 (i+96,1:nf))+(pot_RN2_168_n1_Am3
(i+120,1:nf))+(pot_RN2_168_n1_Am3 (i+144,1:nf));
        pot_24_RN_Am3=pot_24_RN1_Rec./7
        pot_RN_final_Am3=[pot_RN_final_Am3; pot_24_RN_Am3]

    end

matriz_RN_Am3=[]

for i=1:24
    matriz_RN_Am3(i)=sum(pot_RN_final_Am3(i,1:nf))/nf
end

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% GRAFICAS %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

figure(1)
t=1:24
plot(t,total_graf_med,'k')
hold on
plot(t,total_graf_fuz,'--b')
hold on
plot(t,matriz_RN_Am3,'--r')

```

```

grid
title('Previsão de demanda de energia elétrica nos Chuveiros Elétricos (W)')
xlabel('Tempo em horas')
ylabel('Potência (W)')
legend('Medição', 'Modelagem Fuzzy', 'Modelagem Redes Neurais')
axis([1 24 0 500])

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% ANALISES DE ERROS %%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

%MAE
x_gerall=total_graf_med
y_gerall_RN=matriz_RN_Am3
MAE_gerall_RN=mean_avg(x_gerall,y_gerall_RN) % Mean Average Error RN

%MAPE
MAPE_gerall_RN=mean_perc(x_gerall,y_gerall_RN) % Mean Average Error RN

d) Algoritmo Eficiencia

clc
clear all

load total

figure(1) %Comparacao sem e troca de geladeiras
bar(Total);
xlabel('Domicílios')
ylabel('Energia (kWh)')
title('a)')
legend('CE', 'CECET')
axis([0 38 0 35])
grid

energia=Total(:,1)
energia_e=Total(:,2)

figure(2)
porcentagem=((energia-energia_e)./energia)*100
bar(porcentagem)
xlabel('Domicílios')
ylabel('Porcentagem (%)')
title('b)')
axis([1 38 -15 90])
grid

```

d) Curvas de previsões e erros

```
clc  
clear all  
  
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%  
SAMPLE 2 BEFORE RJ HEAT RECOVERY %%%%%%%%%%  
load graf med
```

```

load graf_RN

load graf_fuzzy

%MAE
x_cont=graf_med
y_cont_RN=graf_RN
y_cont_Fuzzy=graf_fuzzy
MAE_cont1_RN=mean_avg(x_cont,y_cont_RN) % Mean Average Error RN
MAE_cont1_Fuzzy=mean_avg(x_cont,y_cont_Fuzzy) % Mean Average Error Fuzzy

%MAPE
MAPE_cont1_RN=mean_perc(x_cont,y_cont_RN) % Mean Average Error RN
MAPE_cont1_Fuzzy=mean_perc(x_cont,y_cont_Fuzzy) % Mean Average Error Fuzzy

figure(1)
t=1:24
plot(t,graf_med,'k')
hold on
plot(t,graf_RN,'--b')
hold on
plot(t,graf_fuzzy,'--r')
title('Previsão de demanda de energia elétrica nos chuveiros (W)')
xlabel('Tempo em horas')
ylabel('Potência (W)')
legend('Medição Direta','Fuzzy','Rede Neural')
grid
axis([1 24 0 500])

%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%% SAMPLE 2 AFTER RJ HEAT RECOVERY %%%%%%%%%
%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%%

load graf_med2

load graf_RN2

load graf_fuzzy2

figure(2)
t=1:24
plot(t,graf_med2,'k')
hold on
plot(t,graf_RN2,'--b')
hold on
plot(t,graf_fuzzy2,'--r')
title('Previsão de demanda de energia elétrica nos chuveiros (W)')
xlabel('Tempo em horas')
ylabel('Potência (W)')
legend('Medição Direta','Fuzzy','Rede Neural')
grid
axis([1 24 0 500])

%MAE
x_cont2=graf_med2
y_cont_RN2=graf_RN2
y_cont_Fuzzy2=graf_fuzzy2
MAE_cont2_RN=mean_avg(x_cont2,y_cont_RN2) % Mean Average Error RN
MAE_cont2_Fuzzy=mean_avg(x_cont2,y_cont_Fuzzy2) % Mean Average Error Fuzzy

```

```
%MAPE
MAPE_cont2_RN=mean_perc(x_cont2,y_cont_RN2)    % Mean Average Error RN
MAPE_cont2_Fuzzy=mean_perc(x_cont2,y_cont_Fuzzy2)    % Mean Average Error
Fuzzy
```